



Guillaume Alexandre Pinto Figueira

Licenciatura em Ciências de Engenharia Química e Bioquímica

**Implementação de técnicas de previsão
para monitorização do fim de ciclo de
permutadores de calor na unidade de
*Hydrocracking***

Dissertação para obtenção do Grau de Mestre em
Engenharia Química e Bioquímica

Orientador: Sérgio Moutinho, Responsável Fábrica III,
Refinaria de Sines
Coorientador: Mário Eusébio, Professor Auxiliar, FCT/UNL

Júri:

Presidente: Professor Doutor Joaquim Silvério Marques Vital, FCT/UNL
Arguente: Professor Doutor José Paulo Barbosa Mota, FCT/UNL
Vogal: Engenheiro Sérgio Miguel da Silva Moutinho, Galp Energia



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Setembro 2017

**Implementação de técnicas de previsão
para monitorização do fim de ciclo de
permutadores de calor na unidade de
*Hydrocracking***

Dissertação para obtenção do Grau de Mestre em
Engenharia Química e Bioquímica

Orientador: Sérgio Moutinho, Responsável Fábrica III,
Refinaria de Sines
Coorientador: Mário Eusébio, Professor Auxiliar, FCT/UNL

Setembro, 2017

Implementação de técnicas de previsão para monitorização do fim de ciclo de permutadores de calor na unidade de *hydrocracking*

Copyright © Guillaume Alexandre Pinto Figueira, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

O tempo diz o que a razão não pode dizer, René Descartes

Agradecimentos

Gostaria de agradecer a todos os intervenientes nesta dissertação e aos que contribuíram na definição de todo o meu percurso académico.

Agradecer à refinaria de Sines, e em particular ao Eng. Martinho Correia pela oportunidade concedida para a elaboração do estágio.

Agradecer ao meu orientador, Eng. Sérgio Moutinho pela motivação dada no desenvolvimento deste trabalho, pelo potenciamento da minha autonomia e capacidade de resolução de problemas.

Agradecer ao meu coorientador, Professor Mário Eusébio por todos estes meses de educação académica, pela fantástica disponibilidade, e por ter tornado possível a consolidação de tudo o que aprendi ao longo do curso.

Agradecer a todos os que ao longo desta dissertação me apoiaram de uma forma ou de outra ao longo deste estágio, e em particular ao Eng. João Pedro Marques e ao Eng. Paulo Fonseca. E quero agradecer de uma forma geral a todos os operadores, chefes de turnos, e equipa de tecnologia que contribuíram de uma forma ou de outra na conclusão desta etapa.

Por fim, e certamente não por último, agradecer a toda a minha família, e em especial aos meus pais pela fantástica educação e valores transmitidos ao longo destes últimos 25 anos, que tornaram possível atingir esta fase da minha vida. Agradecer ao meu irmão por tudo que ele representa para mim. Agradecer a todos os amigos de infância e de faculdade que estiveram presentes ao longo destes anos e que contribuíram de forma direta para a conclusão desta dissertação.

Resumo

A monitorização da *performance* em permutadores de calor é uma preocupação técnica que apresenta cada vez maior relevância na indústria química e em especial na indústria de refinação. Sendo a refinaria de Sines o principal complexo de refinação a nível nacional, encontra-se uma oportunidade para implementação de técnicas que permitam tomar medidas preventivas na perspetiva de um melhoramento a nível energético e consequentemente económico e ambiental.

A presente dissertação tem por objetivo a criação de técnicas que permitam prever a evolução da *performance* em permutadores de calor na unidade de *hydrocracking* através do cálculo da eficiência térmica, utilizando as temperaturas como principais variáveis. Para o estudo foram analisados 6 permutadores de calor.

Na previsão da eficiência foram utilizadas extrapolações de regressões lineares simples para todos os permutadores analisados, e ainda uma rede neuronal para apenas um dos permutadores. Para o efeito foi utilizado o programador *Visual Basic for Applications* do *Microsoft Excel*, pela sua facilidade de utilização, e automatismo na recolha das variáveis a partir da base de dados da refinaria.

Após estimar a eficiência térmica verificou-se que esta é principalmente influenciada por variações na quantidade de caudal, pela composição do mesmo, e pela influência das condições de operação de outros equipamentos que se encontrem a montante ou a jusante do permutador.

A partir da implementação das técnicas de previsão conclui-se que os modelos lineares são suficientemente robustos para a previsão do fim de ciclo em permutadores de calor, excetuando casos em que se verifiquem flutuações significativas no histórico da eficiência térmica. A rede neuronal é um modelo mais complexo que memoriza padrões mais antigos e que devolve previsões não lineares de acordo com esses padrões memorizados.

Após a obtenção das previsões foram definidos indicadores que permitem determinar em que momento o nível de eficiência térmica dos permutadores é baixo, concluindo-se que os permutadores de calor HC-E-21, HC-E-25 e HC-E-31 são os que apresentam maiores preocupações.

Palavras-chave: Permutadores de calor, *Performance*, Eficiência térmica, Estimativa, Previsão.

Abstract

The performance monitorization in heat exchangers is a technical concern that is increasingly gaining importance in the chemical industry, especially in the refinery industry. The Sines refinery plant is the main refining complex in Portugal and therefore it is possible to find an opportunity to implement technics to make preventive decisions that can improve the refinery plant goals at energetic level, and consequently environmentally and economically.

The main objective in the present dissertation are the development of technics that can allow a prevision of the performance evolution of the hydrocracking process unit heat exchangers, through the calculation of a measure of performance called thermal efficiency, using temperatures as main variables. For this study 6 heat exchangers were analysed.

In the thermal efficiency prevision, simple linear regression extrapolation was used for all selected heat exchangers, and a neural network for only one of them. To accomplish the development of that kind of model, the *Microsoft Excel* programmer *Visual Basic for Application* was used, due to its simplicity to access the refinery data base.

After historical determination of the thermal efficiency, it has been observed that it is mainly affected by flow variations and flow compositions, and due to other equipment operational conditions that can be found in the heat exchanger neighbourhood.

Through the implementation of prevision technics, it can be concluded that linear models are sufficiently robust to predict the heat exchanger end cycle, except if heavy variations are verified in the thermal efficiency historical data. The neural network is a much more complex model, it can memorize older patterns, giving non-linear previsions according to those memorized patterns.

After obtaining the previsions for all heat exchangers, efficiency indicators have been defined to determinate if the model gives low values of thermal efficiency for each heat exchanger. The biggest concerns are about heat exchangers HC-E-21, HC-E-25 and HC-E-31.

Key words: Heat exchangers, Performance, Thermal efficiency, Estimation, Prevision

Índice

1	Enquadramento e motivação	1
1.1	Abordagem	3
2	Caso de Estudo	5
2.1	Descrição processual	5
2.2	Problemática em estudo.....	6
2.2.1	Permutadores de calor	8
3	Introdução.....	17
3.1	Fouling em permutadores de calor	17
3.2	Performance em permutadores de calor	18
3.2.1	Coeficiente global de transferência de calor.....	19
3.2.2	Eficiência térmica.....	22
3.2.3	Fator de limpeza	24
3.3	Filtros de ruído e estimadores.....	25
3.3.1	Métodos de Filtragem.....	26
3.3.2	Regressão Linear Simples	28
3.4	Modelos de previsão.....	33
3.4.1	Filtro de Kalman híbrido	33
3.4.2	Modelos de extrapolação da regressão linear	34
3.4.3	Redes Neurais.....	35
4	O modelo de estimação e de previsão	41
4.1	Obtenção dos dados relativos às variáveis	41
4.2	Funções aplicadas aos modelos.....	43
4.2.1	Função de conversão de caudais volumétricos para mássicos	43
4.2.2	Função de determinação da C_{min} , e do rácio entre taxas	44
4.2.3	Função de eficiência térmica.....	45
4.2.4	Função do coeficiente global de transferência de calor.....	45
4.3	Implementação do tratamento de dados	45
4.3.1	Eliminação de dados.....	46
4.3.2	Correção das falhas de medição	47
4.3.3	Remoção dos Outliers	47
4.3.4	Redução do ruído de medição	48
4.3.5	Definição do valor de U limpo	49
4.3.6	Fator de limpeza	50
4.4	Implementação do modelo de previsão	50

4.4.1	Algoritmo de estimação.....	50
4.4.2	O algoritmo de previsão	51
4.4.3	Inferências estatísticas e identificação dos indicadores.....	52
4.4.4	Implementação da rede neuronal.....	52
4.4.5	Funcionamento do modelo	53
5	Discussão dos resultados obtidos	55
5.1	Determinação das propriedades físicas dos fluídos.....	55
5.2	Definição das eficiências ótimas	57
5.2.1	Histórico de Paragens	57
5.2.2	Indicador de eficiências.....	57
5.3	Efeito das variáveis na eficiência térmica	59
5.3.1	Permutador de calor HC-E-21	60
5.3.2	Permutador de calor HC-E-22.....	64
5.3.3	Permutador de calor HC-E-24.....	67
5.3.4	Permutador de calor HC-E-25.....	70
5.3.5	Permutador de calor HC-E-31	73
5.3.6	Permutador de calor HC-E-46.....	76
5.4	Comparação do filtro com os dados medidos.....	79
5.5	Validação dos métodos.....	83
5.5.1	Modelo Linear	83
5.5.2	Rede Neuronal	91
5.6	Teste dos modelos de previsão	94
5.6.1	Modelo Linear	95
5.6.2	Rede Neuronal	104
6	Conclusões	107
7	Trabalho futuro.....	111
	Bibliografia.....	113
	Anexo I.....	117
	Anexo II.....	119
	Anexo III	123
	Anexo IV	139

Índice de tabelas

Tabela 2.1- Permutadores de calor da unidade de Hydrocracking	7
Tabela 2.2-Dados do licenciador para o permutador de calor HC-E-21	9
Tabela 2.3- -Dados do licenciador para o permutador de calor HC-E-22	10
Tabela 2.4 - Dados do licenciador para o permutador de calor HC-E-24	11
Tabela 2.5 - Dados do licenciador para o permutador de calor HC-E-25	12
Tabela 2.6 -Dados do licenciador para o permutador de calor HC-E-26	12
Tabela 2.7 - Dados do licenciador para o permutador de calor HC-E-31	13
Tabela 2.8 - Dados do licenciador para o permutador de calor HC-E-46	14
Tabela 3.1 – Cálculo da eficiência térmica para diferentes geometrias de permutadores	24
Tabela 3.2 - Cálculo de NTU para diferentes geometrias do permutador	24
Tabela 4.1 - Tag's para obtenção das variáveis temperatura e caudal de cada permutador	42
Tabela 5.1 - Histórico de paragens na unidade de Hydrocracking	57
Tabela 5.2 - Eficiências ótimas e indicadores de baixa eficiência para cada permutador	59
Tabela 5.3 - Variação da LMTD, eficiência e U com a diminuição das variáveis	60
Tabela 5.4- Indicadores estatísticos para as validações no permutador HC-E-21 após a paragem de 2016	85
Tabela 5.5 - Indicadores estatísticos para as validações no permutador HC-E-22 após a paragem de 2016	87
Tabela 5.6 - Indicadores estatísticos para as validações no permutador HC-E-24 após a paragem de 2016	88
Tabela 5.7 - Indicadores estatísticos para as validações no permutador HC-E-25 após a paragem de 2016	89
Tabela 5.8 - Indicadores estatísticos para as validações no permutador HC-E-31 após a paragem de 2016	90
Tabela 5.9 - Indicadores estatísticos para as validações no permutador HC-E-46 após a paragem de 2016	91
Tabela 5.10 - Resultados obtidos na fase de treino e validação para a rede neuronal	94

Tabela 5.11 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-21	97
Tabela 5.12 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-22	98
Tabela 5.13 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-24	100
Tabela 5.14 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-25	101
Tabela 5.15 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-31	103
Tabela 5.16 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-46	104

Índice de figuras

Figura 2.1 - Diagrama de Pareto para seleção dos permutadores de calor a serem estudados	8
Figura 2.2-Representação do permutador de calor HC-E-21	9
Figura 2.3 - Representação do permutador de calor HC-E-22	10
Figura 2.4- Representação do permutador de calor HC-E-24	11
Figura 2.5- Representação do permutador de calor HC-E-25	11
Figura 2.6- Representação do permutador calor HC-E-26	12
Figura 2.7 - Representação permutador de calor HC-E-31	13
Figura 2.8 - Representação do permutador de calor HC-E-46	14
Figura 2.9 - Esquematização da integração entre os permutadores de calor selecionados.....	16
Figura 3.1- Permutador de calor sob o efeito do fouling, no lado externo [16]	18
Figura 3.2 - Variação de temperaturas num permutador contracorrente	20
Figura 3.3 - Variação de temperaturas num permutador coocorrente	21
Figura 3.4 - Ilustração das temperaturas para cálculo da eficiência.....	23
Figura 3.5- Esquematização do algoritmo de médias móveis	26
Figura 3.6 - Esquematização de uma rede neuronal.....	37
Figura 4.1 - interface do sistema DCS à esquerda, utilização do Aspen Process Explorer a partir do Excel à esquerda.....	41
Figura 4.2 - Atuação do filtro de mínimos quadrados	49
Figura 4.3 - Interface do modelo linear e da rede neuronal para o permutador HC-E-21	53
Figura 4.4 - Fluxograma do modelo linear	54
Figura 5.1 - Fração de vapor em função das temperaturas de entrada no permutador HC-E-21. Dados disponibilizados pelo licenciador	56
Figura 5.2 - Eficiência térmica em função de NTU e Cr. [20]	58
Figura 5.3 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-21	62
Figura 5.4 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-21 ...	62
Figura 5.5 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-21 ..	63

Figura 5.6 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-21	63
Figura 5.7 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-22	65
Figura 5.8 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-22 ...	65
Figura 5.9 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-22 ..	66
Figura 5.10 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-22	66
Figura 5.11 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-24	68
Figura 5.12 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-24 .	68
Figura 5.13 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-24	69
Figura 5.14 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-24	69
Figura 5.15 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-25	71
Figura 5.16 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-25 .	72
Figura 5.17 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-25	72
Figura 5.18 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-25	73
Figura 5.19 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-31	74
Figura 5.20 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-31 .	75
Figura 5.21 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-31	75
Figura 5.22 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-31	76
Figura 5.23 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-46	77
Figura 5.24 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-46 .	78
Figura 5.25 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-46	78
Figura 5.26 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-46	79

Figura 5.27- filtragem dos dados medidos por mínimos quadrados com 28 pontos	80
Figura 5.28- filtragem dos dados medidos por mínimos quadrados com 56 pontos	81
Figura 5.29- filtragem dos dados medidos por mínimos quadrados com 84 pontos	81
Figura 5.30- filtragem dos dados medidos por mínimos quadrados com 180 pontos	82
Figura 5.31- filtragem dos dados medidos por mínimos quadrados com 240 pontos	82
Figura 5.32- filtragem dos dados medidos por mínimos quadrados com 360 pontos	83
Figura 5.33 - Validação para a previsão de 6 meses no permutador HC-E-21 após a paragem de 2016	84
Figura 5.34 - Validação para a previsão de 6 meses no permutador HC-E-22 após a paragem de 2016	86
Figura 5.35 - Validação para a previsão de 6 meses no permutador HC-E-22 após a paragem de 2014	86
Figura 5.36 - Validação para a previsão de 6 meses no permutador HC-E-24 após a paragem de 2016	87
Figura 5.37 - Validação para a previsão de 6 meses no permutador HC-E-25 após a paragem de 2016	88
Figura 5.38 - Validação para a previsão de 6 meses no permutador HC-E-31 após a paragem de 2016	89
Figura 5.39 - Validação para a previsão de 6 meses no permutador HC-E-46 após a paragem de 2016	90
Figura 5.40 - Validação da rede neuronal com 6 neurónios para o permutador HC-E-21	92
Figura 5.41 - Validação da rede neuronal com 7 neurónios para o permutador HC-E-21	92
Figura 5.42 - Validação da rede neuronal com 9 neurónios para o permutador HC-E-21	93
Figura 5.43 - Validação da rede neuronal com 12 neurónios para o permutador HC-E-21	93
Figura 5.44 - Validação da rede neuronal com 15 neurónios para o permutador HC-E-21	94
Figura 5.45 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-21	96
Figura 5.46 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-22	98
Figura 5.47 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-24	99
Figura 5.48 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-25	101
Figura 5.49 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-31	102

Figura 5.50 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-46	104
Figura 5.51 -Resultados da previsão obtida pela rede neuronal no permutador HC-E-21	105

Glossário

AK – Unidade de Aminas da fábrica 3 do complexo de refinação de Sines

C – Taxa de capacidade calorífica

DCS – *Distributed Control System*

HC – Unidade de *Hydrocracking* da fábrica 3 do complexo de refinação de Sines

HT – Unidade de *Steam reforming* da fábrica 3 do complexo de refinação de Sines

IEA – *International Energy Association*

GPL – Gás de petróleo líquido

LMTD – Diferença de temperatura média logarítmica

NTU – Número de unidades de transferência

PSA – *Pressure swing adsorption*

TEMA – *Tubular Exchangers Manufacturers Association*

VBA – *Visual Basic for applications*

LVGO – Gasóleo de vácuo líquido

SC – Unidade de remoção de enxofre

SW – Unidade de tratamento de águas ácidas

TEMA – *Tubular Exchanger Manufacturers Association*

1 Enquadramento e motivação

O crescimento populacional e económico tem exercido uma forte influência sobre a procura global por energia, aumentando a capacidade de expansão da economia mundial e os parâmetros de vida de milhões de pessoas [1]. Ao observarmos o mundo que nos rodeia é impossível conduzirmos um carro, operar uma fábrica, fazer compras ou entregar bens ou serviços sem despendar uma determinada forma de energia, tornando-a indispensável à vida humana [2].

Segundo o *World Energy Outlook* de 2016, elaborado pelo *IEA*, é previsto que entre 2014 e 2040 exista uma redução de 13% na quantidade de energia primária utilizada em virtude do aumento da eficiência energética nas empresas de todo o mundo, que é hoje em dia um parâmetro indissociável das questões ambientais e económicas [3].

O setor industrial representa cerca de 31% da energia total consumida a nível mundial sendo a indústria da refinação o seu consumidor mais representativo. [4]. Existem refinarias modernas capazes de apresentarem uma maior eficiência energética devido à sua escala, por este ser um setor muito competitivo em que se praticam margens reduzidas levando o negócio da refinação a apresentar elevada concorrência entre empresas dentro deste setor onde metas energéticas têm de ser cumpridas, o que torna a melhoria da eficiência energética nas refinarias fundamental. Desta forma existe uma necessidade para otimizar o uso da energia aplicando não só medidas de redução do consumo, como também medidas para o aumento da eficiência energética, e monitorização de ciclos de vida de equipamentos críticos na *performance* energética.

A indústria da refinação transforma o petróleo bruto em produtos petrolíferos mais úteis, como são exemplo o gasóleo e a gasolina. O petróleo bruto é composto por diversos tipos de hidrocarbonetos e a refinação engloba um conjunto de processos que tira partido dos seus diferentes pesos, volatilidades e temperaturas de ebulição para os separar e dar origem aos produtos intermédios e finais [5]. Existem tipicamente quatro fases [5]:

- Separação física dos hidrocarbonetos através de destilação.
- Purificação de produtos intermédios em unidades de pré-tratamento.
- Processamento químico das frações de menor valor em produtos leves.
- Tratamento e mistura de produtos intermédios por remoção de elementos e compostos indesejáveis para integração em produtos finais.

A gama e a qualidade dos produtos refinados dependem do *blending* de crude utilizado como matéria prima e das estruturas instaladas na refinaria. A complexidade de uma refinaria refere-se, à sua

capacidade de processar matéria prima, como por exemplo crudes mais pesados com maior teor de enxofre, em produtos de valor acrescentado. Normalmente quanto mais elevada a complexidade da refinaria, mais flexível a gama de crudes que a refinaria consegue processar e mais bem posicionada está para tirar partido dos crudes com custos mais baixos, o que resulta num aumento das margens de refinação [5].

A Galp é o grupo português com maior experiência no sector energético. O seu aparecimento começa nos anos pós 25 de abril através da agregação de várias empresas nacionalizadas (SACOR, SIDAL, SONAP e Petrosul) que definiam a indústria do petróleo e gás natural em Portugal, dando origem à Petrogal. Em 1978 nasce a marca Galp que inicia a laboração da refinaria de Sines e em 1999 é formada a Galp energia, completamente detida pelo estado português, que agregava a Petrogal e a GDP (Gás de Portugal), sendo esta privatizada no último dia do mesmo ano [6].

A refinaria de Sines tem uma capacidade de armazenamento de 3 milhões de metros cúbicos dos quais 1.5 milhões são destinados ao petróleo bruto, e possui uma capacidade de destilação de 10.9 milhões de toneladas anuais o equivalente a 220.000 barris diários [7].

A nível energético e ambiental, a Galp tem como um dos seus principais objetivos até 2019, reduzir em 22% a intensidade carbónica na refinaria de Sines, e tem como meta estabelecer um programa de eficiência energética no segmento da refinação e distribuição até 2021.

A consultora *Solomon Associates* desenvolveu um índice de intensidade energética, que compara o consumo de fontes primárias de energia de uma refinaria, com uma refinaria de referência de igual complexidade (*benchmark*), medindo o seu desempenho energético. O índice chama-se de *Energy Intensity Index* ou EII, e baixos valores deste significam menores consumos de energia para os mesmos patamares de produção. Um dos objetivos propostos pela Galp Energia é de atingir os níveis de *benchmark* em eficiência energética, isto é alcançar o 1º quartil até 2019 [8].

O enquadramento desta dissertação insere-se na gestão energética da fábrica 3 do complexo de refinação de Sines através da modelação e implementação de estimadores para monitorização e previsão da eficiência térmica em permutadores de calor. A fábrica 3 é compreendida por três unidades principais, a unidade de *Hydrocracking* (HC), a unidade de *Steam Reforming* (HR), e a unidade de remoção de enxofre (SC), e por mais duas unidades secundária, a unidade de tratamento de aminas (AK), e a unidade de tratamento de águas (SWS).

A motivação desta dissertação passa pela criação de um modelo de estimação da *performance* térmica de permutadores de calor, por forma a se determinar a eficiência futura através dos dados passados. Na possibilidade de alcance às medidas de eficiência energética pretendidas existe uma necessidade para monitorização contínua aos equipamentos subjugados a elevadas trocas caloríficas, pois estes

encontram-se sobre o efeito de corrosão e de incrustações, que reduzem a *performance* obrigando à utilização de fontes de energia dispendiosas externas ao processo aumentando os custos associados.

A consultora *Solomon Associates* efetua a cada dois anos uma análise da eficiência energética na refinaria de Sines, mas a eficiência dos permutadores não é diretamente acompanhada por esta. A análise de *performance* dos permutadores de calor na refinaria é elaborada com base nas medições obtidas após as paragens, e os parâmetros de *design* fornecidos pelo licenciador, relacionando-se o coeficiente global de transferência de calor atual, com o determinado após as paragens. É aqui encontrada uma oportunidade de gestão energética por monitorização de variáveis como caudal e temperatura, em permutadores de calor, de forma a ser possível prever a *performance* térmica destes equipamentos. A previsão atempada da degradação do funcionamento do permutador trará benefícios a nível da gestão, da organização e a nível económico e processual na fábrica, por forma a se encontrar estratégias de intervenção nestes equipamentos, ou a realização de intervenções preventivas sobre o processo por forma a diminuir os problemas de diminuição de eficiência.

1.1 Abordagem

Nesta dissertação será seguida uma abordagem que enfoque os graus de confiança sobre os dados de previsão obtidos através dos modelos criados. O cálculo do desempenho de cada permutador de calor será determinado pela eficiência térmica que utiliza as temperaturas como principais variáveis, sendo estas mais facilmente observadas a partir da consola da refinaria.

Será utilizada a linguagem de programação *VBA* em ambiente *Microsoft Excel*, que permitirá de forma rápida e eficiente a obtenção dos dados através da base de dados e o seu tratamento, estimando os valores sujeitos a falhas nas medições e projetando o decaimento da *performance* dos permutadores de calor.

Após a elaboração dos modelos será determinado o nível de eficiência ótimo para cada permutador de calor por forma a se obter os valores ideais de funcionamento para cada um dos equipamentos estudados. Após estas análises é determinado o grau de confiança a cada parâmetro calculado através dos algoritmos de estimação e de previsão, por forma a saber a incerteza associada aos resultados obtidos.

2 Caso de Estudo

2.1 Descrição processual

A fábrica 3 do complexo de refinação de Sines possui uma capacidade de processamento de 43 000 barris diários, o equivalente a 1792 barris horários. Esta inclui uma unidade de reação composta por dois estágios, o *Hydrocracker* com uma secção de fracionamento, uma unidade de *steam reforming*, uma unidade de remoção de enxofre, e uma unidade de regeneração de aminas. O principal objetivo da fábrica 3 passa por manter uma alta conversão do *LVGO* em destilados médios como querosene, *jet fuel* ou gasóleo.

Unidade de *Hydrocracking*

A unidade de *Hydrocracking* é uma unidade catalítica que tem como objetivo promover a conversão de um produto menos nobre, o *LVGO*, proveniente das destilações atmosférica das refinarias de Sines e de Matosinhos e de importação, em produtos mais valiosos e com muito boas características para a constituição dos lotes de produtos finais expedidos pela refinaria. Dos produtos, destacam-se o gasóleo e o *jet-fuel*, embora também se produzam naftas e *GPL*. A unidade instalada é de 99% de conversão [9].

Unidade de *Steam Reforming*

A unidade de *Steam Reforming* foi desenhada para receber carga de gás natural, tendo como carga alternativa, nafta ligeira dessulfurada. A unidade consiste numa secção de síntese de hidrogénio (incluindo o tratamento da carga), sistema de conversão de alta temperatura e uma unidade *Pressure Swing Adsorption* (PSA) para purificar o hidrogénio a 99,5% vol. Este hidrogénio é consumido essencialmente pelo *Hydrocracker* [9].

Unidade de remoção de enxofre

A Unidade foi desenhada para converter em enxofre elementar o H_2S e remover o NH_3 , das correntes de gás ácido provenientes das unidades de aminas e águas ácidas do *Hydrocracker* e das restantes unidades de aminas da refinaria. A eficiência de recuperação de enxofre da unidade garantida é de 99.5% [9].

2.2 Problemática em estudo

As refinarias estabelecem metas de desempenho com vista a garantir a melhoria da ecoeficiência operacional. Estas metas procuram atender às diversas exigências e requisitos das normas assumidas pela Gestão assegurando uma melhoria contínua. Essas exigências são atendidas através de normas ambientais e energéticas, que no caso da refinaria de Sines é seguida pela norma ISO-50001 [8]. Esta fornece uma base para as organizações demonstrarem que implementam uma gestão eficaz a nível energético, e permitir a essas organizações estabelecer os sistemas e processos necessários para melhorar o seu desempenho energético global [10].

A monitorização da eficiência de permutadores de calor é uma preocupação técnica e económica com elevada relevância para qualquer tipo de indústria, e em especial para a indústria de refinação. O funcionamento pouco adequado de qualquer permutador crítico na linha de processo pode ter um impacto significativo na produção [11]. Os permutadores de calor podem ter uma gama considerável de problemas que podem provocar a diminuição da sua *performance* térmica ou mesmo poder fazê-los parar por completo. O mais comum desses problemas deve-se ao *fouling*, incrustações, que podem acontecer no interior e no exterior das paredes dos tubulares e diminuir significativamente a eficiência dos permutadores e até mesmo danificar o material dos mesmos a longo prazo [11]. A degradação dos permutadores provoca problemas associados com a produção fabril aumentando a operação de fábrica e os custos de manutenção [11].

Observando os problemas anteriormente referidos, o presente estudo dedicou-se na elaboração de medidas de análise que possibilitem a deteção atempada da formação de incrustações na área de transferência dos permutadores de calor na unidade de *hydrocracking*. Na sequência dos efeitos indesejáveis provocados pelo *fouling*, foi proposto que se procedesse à determinação do funcionamento crítico dos permutadores de calor através de modelos que pudessem determinar, a partir do histórico dos mesmos, quando estes atingiriam valores indesejáveis ao funcionamento da unidade.

A medição da eficiência em permutadores de calor já é acompanhada na refinaria, procedendo-se à utilização do coeficiente global de transferência de calor como principal fator na avaliação da evolução do *fouling*. Os métodos propostos neste trabalho visam não só determinar a evolução do *fouling*, mas também analisar a *performance* do permutador de calor quando este é sujeito a variações nas condições de operação e cargas utilizadas, através do acompanhamento das variações nas temperaturas de entrada e saída no permutador de calor, bem como os seus caudais de passagem.

A partir desta análise baseada nas variáveis medidas em linha, pretende-se determinar o comportamento futuro dos permutadores de calor, por forma a se encontrar estratégias ótimas de paragens, ou de limpeza para estes equipamentos e identificar padrões atípicos de *fouling*, permitindo que a equipa de processo identifique quais as variáveis processuais responsáveis por este padrão.

Pretendeu-se efetuar a análise referida aos permutadores de calor da unidade de *hydrocracking*, que apresentem as maiores trocas caloríficas, e que envolvem maiores quantidades de caudal de passagem e variações de temperatura. Na tabela 2.1 encontram-se todos os permutadores de calor presentes na unidade de *Hydrocracking*, bem como o calor trocado por cada um deles e o seu coeficiente global de transferência de calor, com base nos dados de *design*. Os geradores de vapor não foram considerados para esta análise.

Tabela 2.1- Permutadores de calor da unidade de Hydrocracking

Permutadores de calor	Calor trocado (Gcal/h) (design)	Coef. Global de transferência de calor (Kcal/h.m ² .°C) (design)
HC-E-21 A/B	51,7	344,7
HC-E-22	25,1	421,7
HC-E-26	12,5	545,2
HC-E-46	11,3	511
HC-E-25	11,1	467,8
HC-E-24	9,2	512,2
HC-E-31	9,2	460
HC-E-40	4,9	764,4
HC-E-42	4,7	624
HC-E-29	4,6	374,6
HC-E-28	2,9	612
HC-E-23	2,4	505,6
HC-E-81	1,9	1900
HC-E-27	1,8	542
HC-E-33	1,6	992,3
HC-E-38	1,6	363,2
HC-E-34	1,5	1111,7
HC-E-35	1,5	1093,7
HC-E-66	1,3	2975
HC-E-32	0,96	660,2
HC-E-48	0,92	867
HC-E-47	0,71	331
HC-E-44	0,54	396,3
HC-E-37	0,52	473
HC-E-80 A/B	0,38	374
HC-E-30	0,32	553
HC-E-41	0,23	510
HC-E-36	0,18	447
HC-E-52	0,18	604,1
HC-E-82	0,15	363,9
HC-E-39	0,1	332
HC-E-63	0,09	895
HC-E-71	0,08	717,1
HC-E-84	0,03	554,5

A partir do diagrama de *Pareto* representado na figura 2.1 determinou-se quais os permutadores que procediam a uma maior troca de calor na unidade de *Hydrocracking*. O Diagrama de *Pareto* corresponde a um gráfico de frequências e ilustra a contribuição relativa de cada causa para o problema em análise. Para a sua seleção utilizou-se o critério 80/20, com ilustrado na figura 2.1 em que 80% da energia total trocada na unidade corresponde aos primeiros 7 permutadores de calor. O resultado exato e de 78% da energia trocada corresponde a 22% dos permutadores presentes na unidade. Os permutadores de calor selecionados foram o HC-E-21, HC-E-22, HC-E-24, HC-E-25, HC-E-26, HC-E-31 e HC-E-46. O permutador de calor HC-E-26 foi excluído de futuras análises devido a este possuir um sistema de lavagem integrado, sendo este normalmente limpo a cada 7 ou 15 dias.




Figura 2.1 - Diagrama de Pareto para seleção dos permutadores de calor a serem estudados

2.2.1 Permutadores de calor

Os Permutadores de calor são equipamentos desenhados para que se proceda à troca calorífica de uma corrente a uma dada temperatura por outra corrente que se encontre a uma mais baixa temperatura. Estes são normalmente construídos de forma a que não exista contacto no seu interior entre as correntes sendo estes divididos por uma parede entre uma das passagens, o corpo, e a outra passagem, os tubos. Dentro da indústria de refinação os permutadores são de extrema importância, pois possibilitam a variação de temperatura dos compostos por forma a que estes possam ser separados por colunas de fracionamento, aquecer a corrente de alimentação a reatores, permitir a integração energética entre correntes para aproveitamento de energia de maneira a que não exista necessidade de se utilizar fontes externas ao processo, ou para separação em colunas de destilação. Nas indústrias de refinação a maioria dos

permutadores de calor utilizados são os de corpo e tubos, selecionados e classificados segundo o *TEMA* (*Tubular Exchanger Manufacturers Association*) [12]. Nos parágrafos seguintes encontram-se detalhados os permutadores de calor que envolvem maiores trocas caloríficas na unidade de *Hydrocracking* da fábrica 3 do complexo de refinação de Sines.

HC-E-21 A/B

O permutador de calor ilustrado na figura 2.2, é do tipo *DEU* (*Special high pressure closure, one pass Shell, U-tube bundle*).

Este permutador de calor procede à integração energética entre a carga de alimentação (mistura líquido-gás) ao reator HC-R-01 (tubos), e a corrente efluente (mistura líquido-gás) do mesmo (corpo). Aquece a primeira corrente arrefecendo a segunda. As suas especificações encontram-se na tabela 2.2.




Figura 2.2-Representação do permutador de calor HC-E-21

Tabela 2.2-Dados do licenciador para o permutador de calor HC-E-21

Tipo permutador	<i>High pressure shell and tube</i>
Nº unidades	2
Área por unidade (m^2)	1098
Nº tubos por unidade	1620
Nº passagem corpo	1
Nº passagem tubos	2
Temperatura design corpo ($^{\circ}C$)	454
Temperatura design tubos ($^{\circ}C$)	444
Pressão de design corpo (bar)	177
Pressão de design tubos (bar)	194.1

HC-E-22

O permutador de calor ilustrado na figura 2.3, é do tipo *DFU* (*Special high pressure closure, two pass Shell with longitudinal baffle, U-tube bundle*).

Este permutador de calor procede à integração energética entre a carga de alimentação (mistura líquido-gás) ao reator HC-R-02 (tubos), e a corrente de saída (mistura líquido-gás) do mesmo (corpo). Aquece a primeira corrente arrefecendo a segunda. As suas especificações encontram-se na tabela 2.3.




Figura 2.3 - Representação do permutador de calor HC-E-22

Tabela 2.3- -Dados do licenciador para o permutador de calor HC-E-22

Tipo permutador	High pressure Shell and tube
Nº unidades	1
Área por unidade (m^2)	1154
Nº tubos por unidade	2642
Nº passagem corpo	2
Nº passagem tubos	4
Temperatura design corpo ($^{\circ}C$)	454
Temperatura design tubos ($^{\circ}C$)	417
Pressão de design corpo (bar)	179.3
Pressão de design tubos (bar)	192.1

HC-E-24

O permutador de calor ilustrado na figura 2.4 é do tipo *DEU* (*Special high pressure closure, one pass Shell, U-tube bundle*).

O permutador HC-E-24, arrefece a corrente proveniente dos caudais efluentes (mistura líquido-gás) do reator, estas encontram-se combinadas (tubos), aquecendo a corrente proveniente da coluna de *stripper* HC-V-02 (mistura líquido-gás) que serve de alimentação à coluna fracionamento HC-V-03 (corpo).




Figura 2.4- Representação do permutador de calor HC-E-24

Tabela 2.4 - Dados do licenciador para o permutador de calor HC-E-24

Tipo permutador	<i>High pressure Shell and tube</i>
Nº unidades	1
Área por unidade (m^2)	610.7
Nº tubos por unidade	2146
Nº passagem corpo	1
Nº passagem tubos	2
Temperatura design corpo ($^{\circ}C$)	343
Temperatura design tubos ($^{\circ}C$)	400
Pressão de design corpo (bar)	134
Pressão de design tubos (bar)	174.7

HC-E-25

O permutador de calor ilustrado na figura 2.5, é do tipo *DFU (Special high pressure closure, two pass shel with longitudinal baffles, U-tube bundle)*.

Este permutador arrefece a corrente (mistura líquido-gás) proveniente da coluna de separação HC-V-22 (tubos), aquecendo a corrente (mistura líquido-gás) vinda do HC-V-25 (corpo).




Figura 2.5- Representação do permutador de calor HC-E-25

Tabela 2.5 - Dados do licenciador para o permutador de calor HC-E-25

Tipo permutador	High pressure Shell and tube
Nº unidades	1
Área por unidade (m^2)	570.6
Nº tubos por unidade	1660
Nº passagem corpo	2
Nº passagem tubos	2
Temperatura design corpo ($^{\circ}C$)	260
Temperatura design tubos ($^{\circ}C$)	343
Pressão de design corpo (bar)	131.3
Pressão de design tubos (bar)	170.7

HC-E-26

O permutador de calor ilustrado na figura 2.6, é do tipo *DFU* (*Special high pressure closure, two pass Shell with longitudinal baffle, U-tube bundle*).

Este permutador de calor procede ao aquecimento da corrente combinada de hidrogénio (vapor) proveniente dos compressores de *make-up* e de reciclo (corpo), arrefecendo a corrente (mistura líquido-gás) vinda da coluna de separação a alta temperatura e alta pressão HC-V-22 (tubos).




Figura 2.6- Representação do permutador calor HC-E-26

Tabela 2.6 -Dados do licenciador para o permutador de calor HC-E-26

Tipo permutador	High pressure Shell and tube
Nº unidades	1
Área por unidade (m^2)	763.9
Nº tubos por unidade	2014
Nº passagem corpo	2
Nº passagem tubos	2
Temperatura design corpo ($^{\circ}C$)	343
Temperatura design tubos ($^{\circ}C$)	343
Pressão de design corpo (bar)	196.8
Pressão de design tubos (bar)	170.8

HC-E-31

O permutador de calor ilustrado na figura 2.7, é do tipo AES (*Channel and Removal, one pass Shell, floating head with backing Device*).

O permutador HC-E-31, arrefece a corrente (líquido) proveniente da coluna de *stripper* de *diesel*, HC-V-06 (tubos), aquecendo a corrente (líquido) proveniente dos destilados de vácuo, que servirá de alimentação ao reator HC-R-01 (corpo), com consequentes passagens pelo permutador HC-E-21, e à fornalha HC-F-01.




Figura 2.7 - Representação permutador de calor HC-E-31

Tabela 2.7 - Dados do licenciador para o permutador de calor HC-E-31

Tipo permutador	Shell and tube
Nº unidades	1
Área por unidade (m^2)	375.4
Nº tubos por unidade	872
Nº passagem corpo	1
Nº passagem tubos	4
Temperatura design corpo (°C)	260
Temperatura design tubos (°C)	300
Pressão de design corpo (bar)	14.2
Pressão de design tubos (bar)	18

HC-E-46

O permutador de calor ilustrado na figura 2.8, é do tipo AES (*Channel and Removal, one pass Shell, floating head with backing Device*).

O permutador HC-E-46, arrefece a corrente (líquido) proveniente do fundo da coluna de fracionamento HC-V-03, e aquece a corrente (mistura líquido-gás) vinda do fundo da coluna de produto *stripper* que é aquecida pelos permutadores de calor HC-E-23 e HC-E-24 antes de ser direcionada para o permutador HC-E-46.




Figura 2.8 - Representação do permutador de calor HC-E-46

Tabela 2.8 - Dados do licenciador para o permutador de calor HC-E-46

Tipo permutador	Shell and tube
Nº unidades	1
Área por unidade (m^2)	632
Nº tubos por unidade	1812
Nº passagem corpo	1
Nº passagem tubos	6
Temperatura design corpo ($^{\circ}C$)	308
Temperatura design tubos ($^{\circ}C$)	386
Pressão de design corpo (bar)	21.8
Pressão de design tubos (bar)	28.4

De forma a se analisar corretamente toda a envolvente na eventualidade de uma paragem, deve –se verificar a existência de *bypass*, tempo de reparação e manutenção e como estes podem afetar a produção antes de qualquer intervenção [11]. Com estas proposições estabelecidas, a monitorização de permutadores é elaborada de forma a se poder acompanhar a *performance* de cada permutador com o principal objetivo de se determinar tempos ideais de paragens. A *performance* dos permutadores pode ser obtida através do cálculo das suas trocas caloríficas, quedas de pressão ou cálculo dos coeficientes de transferência de calor.

A monitorização dos permutadores de calor é um processo que não pode ser efetuado sem a medição de valores, obtidos através de instrumentação. Inicialmente essas medições eram realizadas com instrumentos básicos, e os dados apenas eram obtidos manualmente por operados de campo, que tornavam a tarefa com custos associados mais elevados, e uma menor continuidade no acompanhamento dos equipamentos. Atualmente a tecnologia melhorou drasticamente sendo possível uma maior automação no processo de medição de variáveis, sem existir a necessidade de se despendar tempo e mão de obra na recolha dos dados, com a ajuda de sensores digitais e *wireless* [11]. Desta forma para monitorizar a *performance* em permutadores é essencial dispor-se de instrumentação fiável. Das variáveis processuais disponibilizadas aquelas que têm maior grau de confiança são as temperaturas de entrada e de saída porque normalmente estas apresentam pouco erro de medição, e a instrumentação

associada a estas medidas tem poucas avarias. Desta forma o modelo foi desenvolvido utilizando estas variáveis. (caudais podem apresentar erros até 35% na leitura do sensor)

Na figura 2.9 encontra-se representado o esquema de integração de cada permutador anteriormente referido, na unidade de *hydrocracking*. Esta esquematização ilustra a influência existente entre cada um deles e pelos diversos equipamentos presentes na unidade, e identifica onde se encontram os pontos de medição para a obtenção das variáveis.

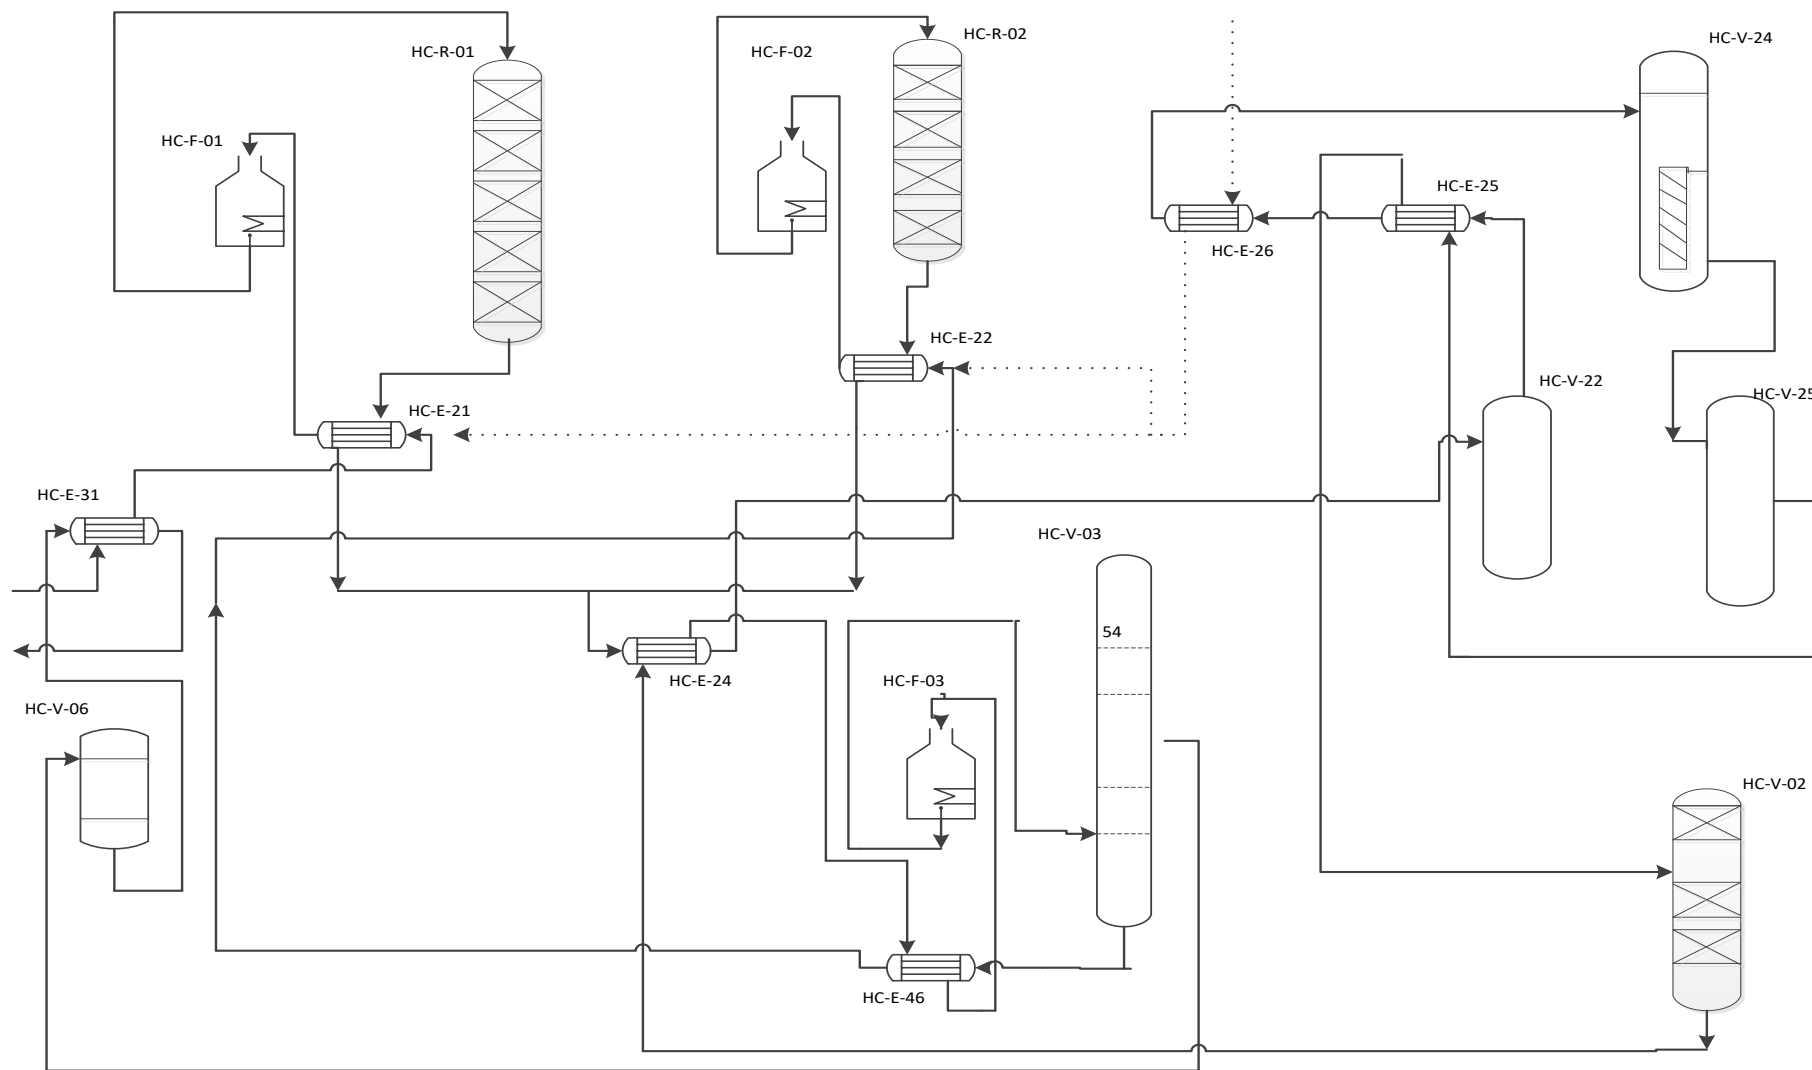


Figura 2.9 - Esquematização da integração entre os permutadores de calor seleccionados

3 Introdução

3.1 *Fouling* em permutadores de calor

O *fouling*, ou incrustações, é definido como a deposição e acumulação de materiais indesejados, formação de detritos e sujidade na área de transferência de calor. O *fouling* diminui a transferência de calor, aumenta a queda de pressão e pode obstruir o fluxo dos fluídos. [13].

A condutividade térmica do *fouling* é mais baixa do que a das paredes dos permutadores o que resulta num aumento da resistência térmica global e diminuição da eficiência energética [13].

Outra das consequências da formação de *fouling* é a diminuição da área da secção reta dos tubos provocada pelo aumento da rugosidade da superfície do permutador de calor aumentando a resistência à passagem do fluído e consequentemente a queda de pressão [13]. Esta pode encontrar-se associada a outros tipos de problemas atuando como uma reação em cadeia, por exemplo muitos dos problemas de fugas em permutadores vêm de uma distribuição de fluxo pouco uniforme o que provoca velocidades mais elevadas dentro do permutador, podendo levar à ocorrência de vibração que pode aumentar o efeito de corrosão dentro do permutador, podendo levar a fugas aumentando a problemática da manutenção e aumentando os custos de manutenção [14].

A presença de partículas na corrente de alimentação pode levar à deposição das mesmas nas superfícies do permutador de calor como consequência de baixas temperaturas que induzem a baixas solubilidades junto das paredes. As partículas são na sua maioria de carácter inorgânico e insolúveis, ou de baixa solubilidade, sendo estes produtos da formação de reações de corrosão, restos de catalisador, sujidade, depósitos de areia ou outros tipos de sais inorgânicos.

As correntes de alimentação também podem conter compostos orgânicos que se formem durante a fase de armazenamento ou de transporte. Para além das correntes de alimentação, outras podem conter partículas sólidas, especialmente na indústria de refinação, quando estas são provenientes de por exemplo unidades de vácuo, unidades de *visbreaker*, ou unidades de fracionamento, devido à natureza mais pesada das correntes processadas [15].

Devido à exposição a oxigénio e ao elevado tempo na sua movimentação, as correntes provenientes de outras refinarias também podem conter elevadas quantidades de partículas como resultado de reações de corrosão [15].

Na grande maioria dos casos a construção apropriada de um permutador de calor pode não prevenir a formação de *fouling*, que não é prevista na sua fase de dimensionamento. Para controlo e mitigação da

formação de *fouling*, é necessário ter em linha de conta as diferenças nas condições operacionais, como diferenciais de temperatura, caudais de alimentação ao permutador de calor, e respectivas composições químicas. Para que se possa minimizar o impacto do *fouling* utilizam-se elevados valores de velocidades de passagem, tendo em consideração a erosão do material de construção do mesmo por forma a respeitar o seu tempo de vida [15].



Figura 3.1- Permutador de calor sob o efeito do *fouling*, no lado externo [16]

3.2 *Performance* em permutadores de calor

Neste subcapítulo serão abordados os vários métodos existentes na determinação da *performance* em permutadores de calor. Apenas serão considerados permutadores individuais, não sendo do âmbito desta dissertação uma abordagem a redes de permutadores de calor, quer seja em série ou em paralelo.

Na maioria das indústrias de processo, um fraco desempenho por parte dos permutadores de calor devido ao *fouling* pode levar a uma quebra na produção influenciada pela incapacidade de manutenção da produção devido à falta de energia, ou devido à obtenção de um produto com temperaturas demasiado elevadas para o armazenamento [17].

3.2.1 Coeficiente global de transferência de calor

As degradações das condições térmicas num permutador de calor podem ser observadas através do decaimento do coeficiente global de transferência de calor. Segundo *Friebel et al. (2009)* este é um parâmetro que é bastante sensível às incrustações e às variações nas correntes de entrada [18].

O coeficiente de transferência de calor é uma medida utilizada no dimensionamento de permutadores de calor, e este é o inverso da soma das resistências térmicas presentes no permutador [19].

Para que os métodos de cálculo deste coeficiente sejam facilitados, é considerado que os permutadores de calor em questão são de dois tubos, onde um dos fluídos circula no lado interno do tubo mais estreito, e o outro fluído na secção anelar entre os dois tubos [19]. Utilizando a equação 3.1 e a equação 3.2 podemos determinar o coeficiente global de transferência de calor através das resistências térmicas num permutador de calor.

$$U_i = \frac{1}{\frac{1}{h_i} + R_{i,i} + \frac{A_i \ln\left(\frac{r_e}{r_i}\right)}{2\pi kL} + \frac{A_i}{A_e} \left(\frac{1}{h_e} + R_{i,e} \right)}$$

Equação 3.1- Coeficiente global de transferência de calor do lado interno

$$U_e = \frac{1}{\frac{A_e}{A_i} \left(\frac{1}{h_i} + R_{i,i} \right) + \frac{A_e \ln\left(\frac{r_e}{r_i}\right)}{2\pi kL} + \frac{1}{h_e} + R_{i,e}}$$

Equação 3.2- Coeficiente global de transferência de calor do lado externo

Onde U_i é o coeficiente global de transferência de calor interno U_o é o coeficiente global de transferência de calor, o h_i é o coeficiente de resistência interno, h_o o coeficiente de resistência externo, r_i o raio interno, r_o o raio externo, A_i a área interna do permutador de calor, A_o a área externa, $R_{i,i}$ coeficiente interno da resistência térmica devido às incrustações $R_{i,e}$ coeficiente externo da resistência térmica devido às incrustações e L o comprimento do permutador.

Existem dois métodos distintos que podem ser utilizados para o cálculo do coeficiente global de transferência de calor, sem que exista a necessidade de se proceder a uma determinação complicada dos coeficientes de resistência térmica do permutador de calor. Estes métodos são o da temperatura média logarítmica (*LMTD*), e o da eficiência térmica com os *NTU* (*NTU-ε*).

LMTD

O coeficiente global de transferência de calor pode ser calculado a partir da equação do balanço energético a um permutador de calor, utilizando para o efeito a área do mesmo e a sua temperatura média logarítmica. Neste método este é determinado utilizando a equação 3.3.

$$Q_{\text{trocado}} = UA\Delta T_{ML}$$

Equação 3.3- Cálculo do coeficiente de transferência de calor pelo método da LMTD

Onde A representa a área do permutador de calor, ΔT_{ML} a diferença de temperatura média logarítmica, e U o coeficiente global de transferência de calor. A equação 3.3 reflete a convecção e a condução do fenómeno de transferência de calor num permutador de calor [20].

A $LMTD$ representa a diferença de temperatura em um extremo do permutador de calor, menos a diferença de temperatura no outro extremo, a dividir pelo natural logaritmo do rácio entre essas duas diferenças de temperatura. A equação 3.4 é utilizada para o cálculo da diferença de temperatura média logarítmica para um permutador de calor que opera em contracorrente, e a equação 3.5 para um permutador que opera em cocorrente. A figura 3.2 e a figura 3.3 representam as variações de temperatura para um permutador de calor contracorrente e cocorrente respetivamente, considerando-se que o fluído da corrente fria apresenta maior variação de temperatura.




Figura 3.2 - Variação de temperaturas num permutador contracorrente

$$LMTD = (T_{saída,quente} - T_{entrada,fria}) - (T_{entrada,quente} - T_{saída,fria})$$

$$* \ln \left(\frac{(T_{saída,quente} - T_{entrada,fria})}{(T_{entrada,quente} - T_{saída,fria})} \right) = \Delta T_2 - \Delta T_1 * \ln \left(\frac{\Delta T_2}{\Delta T_1} \right)$$

Equação 3.4 - Cálculo da diferença de temperatura média logarítmica para permutador contracorrente




Figura 3.3 - Variação de temperaturas num permutador coocorrente

$$LMTD = (T_{entrada,quente} - T_{entrada,fria}) - (T_{saída,quente} - T_{saída,fria})$$

$$* \ln \left(\frac{(T_{entrada,quente} - T_{entrada,fria})}{(T_{saída,quente} - T_{saída,fria})} \right) = \Delta T_2 - \Delta T_1 * \ln \left(\frac{\Delta T_2}{\Delta T_1} \right)$$

Equação 3.5- Cálculo da diferença de temperatura média logarítmica para permutador coocorrente

NTU-ε

No caso de não ser possível calcular a *LMTD* a partir do conhecimento das temperaturas, é utilizada uma abordagem que envolve a eficiência térmica do permutador de calor através do número de unidades de transferência, ou *NTU*, a partir da equação 3.6 e da tabela 3.1. Esta abordagem é de grande vantagem não só para as condições já referidas, mas também porque permite determinar com maior exatidão o coeficiente global de transferência de calor para uma vasta gama de geometrias [19].

$$NTU = \frac{UA}{C_{min}}$$

Equação 3.6 - determinação do número de unidades de transferência

Onde U representa o coeficiente global de transferência de calor, A a área do permutador de calor e C_{min} a taxa de capacidade calorífica mínima.

3.2.2 Eficiência térmica

A eficiência térmica é essencialmente uma medida adimensional, representada sob a forma de percentagem da quantidade de calor que é atualmente transferida no permutador de calor entre duas correntes, normalizada com a quantidade máxima de calor que é possível transferir no sistema [21]. Certos autores consideram esta medida a eficácia do permutador de calor [18], enquanto outros usam a designação de eficiência térmica [22] termo utilizado ao longo desta dissertação. A quantidade hipotética de calor transferida no permutador de calor é vista como a variação de entalpia da corrente com a taxa de capacidade calorífica mais baixa, ou seja que tem uma maior variação de temperatura [21]. Esta é calculada a partir do balanço energético a um permutador de calor representado pela equação 3.7.

$$\begin{aligned} Q_{trocado} &= m_{fria} \cdot cp_{fria} (T_{saída,fria} - T_{entrada,fria}) \\ &= m_{quente} \cdot cp_{quente} (T_{entrada,quente} - T_{saída,quente}) \end{aligned}$$

Equação 3.7- Balanço energético a um permutador de calor

Onde m_{fria} representa o caudal mássico da corrente fria, m_{quente} o caudal mássico da corrente quente, c_p a capacidade calorífica e T a temperatura. O produto entre m e c_p é denominado pela taxa de capacidade calorífica (C), que indica a quantidade de calor transferida por °C [23].

A partir da equação do balanço energético a um permutador de calor é possível obter a equação 3.8, que determina a eficiência térmica para um permutador de calor contracorrente, considerando que a corrente fria apresenta a taxa de capacidade calorífica mínima, C_{min} . A figura 3.4 ilustra as variações de temperatura utilizadas no cálculo da eficiência.

$$\varepsilon = \frac{Q_{\text{atual}}}{Q_{\text{máximo}}} = \frac{C_{\min} \Delta T}{C_{\min} \Delta T_{\max}} = \frac{\Delta T}{\Delta T_{\max}} = \frac{T_{\text{saída, fria}} - T_{\text{entrada, fria}}}{T_{\text{entrada, quente}} - T_{\text{entrada, fria}}}$$

Equação 3.8- Eficiência térmica num permutador de calor




Figura 3.4 - Ilustração das temperaturas para cálculo da eficiência

Analisando a equação 3.8, o termo no denominador representa a quantidade máxima de calor que pode ser transferida no permutador de calor em questão, multiplicando-se a taxa mínima de capacidade calorífica pelas temperaturas de entrada no permutador. Pretende-se com isto afirmar que de acordo com a primeira lei da termodinâmica, não é possível aquecer a corrente de entrada fria a temperaturas superiores da corrente de entrada quente, mesmo que o permutador de calor tendesse para infinito, mas podemos quantificar o quão longe este se encontra de atingir a transferência de calor teórica máxima. Na equação 3.8 toma-se como exemplo que a corrente fria possui a menor taxa de capacidade calorífica [17].

O cálculo da eficiência térmica depende da geometria e do número de unidades de transferência do permutador calor [20]. Isto deve-se ao facto de a análise da eficiência térmica se tornar mais complicada quando o arranjo e geometria do permutador de calor são de maior complexidade. Para calcular a eficiência térmica através das unidades de transferência deve ser conhecido o coeficiente global de transferência de calor. A tabela 3.1 mostra as diferentes equações no cálculo da eficiência térmica em função do número de unidades de transferência térmica. O C_r é a razão entre o C_{\min} e o C_{\max} , sendo este último a taxa de capacidade calorífica do fluído que apresentar menor variação de temperatura.

Tabela 3.1 – Cálculo da eficiência térmica para diferentes geometrias de permutadores

Arranjo do fluxo	Fórmulas de ε -NTU
Fluxo contracorrente	$\varepsilon = \frac{1 - \exp(-NTU(1 - C_r))}{1 - C_r \exp(-NTU(1 - C_r))}$
Fluxo paralelo	$\varepsilon = \frac{1 - \exp(-NTU(1 + C_r))}{1 + C_r}$
Fluxo cruzado (para fluídos misturados ou não misturados)	$\varepsilon = 1 - \exp(-NTU) - \exp\left[-(1 + C_r)NTU \sum_{n=1}^{\infty} C_r^n P_n(NTU)\right]$

Tabela 3.2 - Cálculo de NTU para diferentes geometrias do permutador

Arranjo dos fluxos	Fórmulas
Fluxo Contracorrente	$NTU = \frac{1}{1 - C_r} \ln \frac{1 - C_r \varepsilon}{1 - \varepsilon} \quad (C_r < 1)$ $NTU = \frac{\varepsilon}{1 - \varepsilon} \quad (C_r = 1)$
Fluxo em paralelo	$NTU = -\frac{\ln(1 - \varepsilon(1 + C_r))}{1 + C_r}$
Fluxo cruzado (fluídos misturados)	$NTU = \ln\left(1 + \frac{1}{C_r} \ln(1 - C_r \varepsilon)\right)$
Fluxo cruzado (fluídos não misturados)	$NTU = -\frac{1}{C_r} \ln(1 + C_r \ln(1 - \varepsilon))$

3.2.3 Fator de limpeza

O fator de limpeza é uma medida adimensional de determinação da degradação da *performance* dum permutador de calor. Se este apresentar valores de fator de limpeza próximos de 100% significa que se encontra limpo, diminuindo este valor, ao longo do tempo, com o aumento do *fouling* [24].

Prasad et al. (2005) utiliza o fator de limpeza como método de determinação da *performance*, que segundo o autor é um método alternativo de monitorização da degradação de um permutador de calor, que utiliza como variáveis a temperatura, o caudal e as pressões, por forma a determinar uma data de limpeza para o mesmo.

O valor de referência para o cálculo do fator de limpeza é definido com a obtenção do cálculo do coeficiente global de transferência de calor na última limpeza realizada no permutador de calor, que

normalmente coincide com a última paragem realizada na unidade. A equação 3.9 representa o cálculo do fator de limpeza através dos coeficientes globais de transferência de calor.

$$FL = \frac{U_{sujo, calculado}}{U_{limpo, calculado}} * (100\%)$$

Equação 3.9- Cálculo do fator de limpeza num permutador de calor

3.3 Filtros de ruído e estimadores

Um modelo matemático é um sistema de equações, cuja solução, dado um conjunto de dados de entrada, é representativa da resposta de um processo. Um modelo não consegue incorporar todas as características, tanto macroscópicas como microscópicas do processo real.

Os modelos lineares são mais simples e envolvem propriedades restritas como normalidade e variância constante, e são surpreendentemente versáteis e robustos [25].

A estimativa de parâmetros é o problema que se coloca na determinação de valores de uma dada quantidade a partir de uma ou mais observações [26]. Estes problemas intensificam-se sempre que existe a necessidade de utilizar sensores para obter medições de uma dada quantidade de interesse.

No centro de todos os problemas de estimação encontra-se a necessidade de calcular a incerteza. No caso de existir a possibilidade de obter medições perfeitas, a perceção do que aconteceria nas situações reais seria bastante mais simplista, mas de facto esse não é o caso e as observações obtidas são sempre sujeitas a incertezas ou a ruído [26].

O ruído é um fenómeno causado por uma certa quantia de variações aleatórias no sinal de medição de um sensor ou a problemas de transmissão de sinal, e é reduzido por processos de filtragem e suavização [27]. Este é observável por flutuações que se encontram numa série temporal. Como geralmente os sinais de ruído têm frequências elevadas, este tipo de filtros passa baixo eliminam a maioria desses componentes.

A principal diferença entre filtragem e suavização, são os intervalos de tempo considerados. No caso de apenas se considerarem os tempos passados na série de dados, dá-se o nome de filtragem ao processo, caso se considerem pontos passados e pontos futuros dá-se o nome de suavização [28].

A principal diferença entre a filtragem e a estimação, deve-se principalmente a esta última captar as tendências das medições, aceitando os *outliers* como dados relevantes na estimação de uma série temporal [25, 26].

A estimativa de parâmetros pode ser efetuada através de diferentes modelos lineares, de forma a se obter uma resposta ao processo. Nesta dissertação será utilizada a regressão linear simples como modelo linear para estimativa de dados, a média móvel como modelo de remoção de *outliers*, e o filtro de mínimos quadrados para a filtragem dos dados das séries temporais.

3.3.1 Métodos de Filtragem

Média móvel simples

As médias móveis são uma técnica matemática utilizada principalmente na eliminação de falhas de medição, de *outliers*, e de ruído por forma a revelar a verdadeira tendência de uma série de dados [23, 24]. Porém o filtro de médias móveis pode produzir distorções e reduzir a intensidade do sinal, efeito que é obtido conforme o número de pontos utilizados no filtro [27].

Como o nome indica o filtro de médias móveis opera calculando a média aritmética de um certo número de pontos, presentes numa série de dados, gerando um valor de saída obtido através dessa operação [27]. A vertente móvel do filtro deve-se ao facto de este esquecer o ponto mais antigo e incluir a próxima observação utilizando sempre o mesmo número de pontos no cálculo da média aritmética, como está ilustrado na figura 3.5.

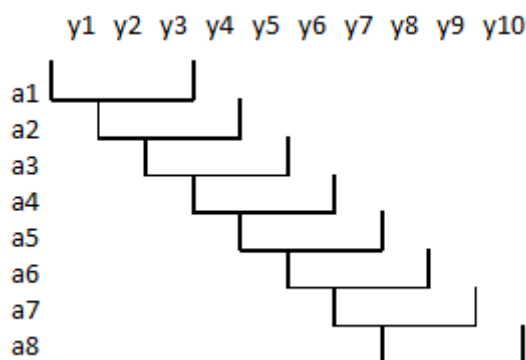


Figura 3.5- Esquematização do algoritmo de médias móveis

No caso do exemplo da figura 3.5 são utilizados 3 termos para produzir um valor filtrado por média aritmética, e o processo continua até chegar ao fim da série de dados.

A ideia básica na utilização de médias móveis para suavização e filtragem encontra-se relacionada com o facto de as observações temporais que se encontram na vizinhança de um dado ponto, também se encontram próximas em termos de valor [32]. Utilizando as médias aritméticas dos pontos vizinhos a

uma dada observação irá fornecer uma estimativa razoável dessa dada observação ou seja, mais próxima do seu valor real eliminando os componentes de alta frequência que parecem dar um certo caráter aleatório à série de dados [32].

A equação 3.10 mostra como se aplica a média móvel simples.

$$a_t = \frac{1}{k+1} \sum_{j=0}^k y_{t-j}, \quad t = k+1, k+2, \dots, n.$$

Equação 3.10- Cálculo de uma média móvel simples

A partir da equação 3.10 também é possível calcular a média móvel centrada que utiliza os pontos antes de y_t , e depois de y_t para calcular a média aritmética do k pontos necessários a produzir o filtro de média móvel pretendido.

Média móvel ponderada

Uma média móvel ponderada com k pontos pode ser descrita pela equação 3.11 em que o parâmetro w_j representa o peso atribuído às observações [33].

$$a_t = \sum_{j=0}^k w_j y_{t-j}, \quad t = k+1, k+2, \dots, n.$$

Equação 3.11- Cálculo de uma média móvel ponderada

Para que uma média móvel ponderada possa funcionar corretamente, é importante que a soma de todos os pesos seja igual a 1, e que estes sejam simétricos. Todavia não é necessário que estes se encontrem apenas entre os valores de 0 e 1 [32]. A utilização de médias móveis ponderadas pode ser de extrema utilidade, resultando numa maior vantagem em relação às médias móveis simples, já que estas proporcionam uma estimativa da tendência da série temporal muito mais suave, e possibilitam retirar importância aos dados que se encontram mais distantes, ponderando as observações que entram e saem dos k pontos utilizados no algoritmo de filtragem [32].

Método de filtragem por mínimos quadrados

A filtragem por mínimos quadrados, ou *running lines smoother*, é um método de eliminação de ruído e de filtragem ou suavização de dados que utiliza a estimativa por mínimos quadrados aplicada a um conjunto de k pontos [34]. Este algoritmo é aplicado a cada ponto y seguinte observado esquecendo a observação inicial, similarmente ao sucedido na filtração por médias móveis. Este método é considerado um melhoramento relativamente ao filtro de médias móveis pois reduz a desvio perto dos pontos que se encontram nos extremos da série dos k pontos utilizados [34].

3.3.2 Regressão Linear Simples

Na regressão linear simples ou simplesmente RLS, pretende-se modelar a reação entre duas variáveis, uma dependente ou de resposta, y , e outra independente ou de predição, x , como pode ser demonstrado pela equação 3.12.

$$y = \beta_0 + \beta_1 x + e$$

Equação 3.12- Modelo de uma regressão linear simples para n observações

A estimativa dos parâmetros β_0 e β_1 , realiza-se por inferências como intervalos de confiança e testes de hipótese, e estimar o valor de y .

De forma a complementar o modelo, e proceder à sua elaboração existem algumas suposições que devem ser tidas em conta [25].

1. $E(e_i) = 0, i = 1, 2, 3 \dots n$, ou equivalentemente, $E(y_i) = \beta_0 + \beta_1 x_i$.
2. $var(e_i) = \sigma^2, i = 1, 2, 3 \dots n$, ou equivalentemente $var(y_i) = \sigma^2$.
3. $cov(e_i, e_j) = 0$, para todo o $i \neq j$, ou equivalentemente $cov(y_i, y_j) = 0$.

A primeira suposição mostra que o modelo da equação 3.12 encontra-se correto, declarando que y_i depende apenas de x_i e que todas as outras variações em y_i são aleatórias [25].

A segunda suposição mostra que a variância de e_i ou de y_i não dependem de x_i [25].

A terceira suposição mostra que as variáveis de e_i , ou de y_i , não se encontram correlacionadas uma com a outra. Ou seja, indica-nos que o resultado em qualquer experiência não tem efeito no termo do erro de qualquer outra experiência [25].

Estimadores de mínimos quadrados

Utilizando uma amostra de n observações y_1, y_2, \dots, y_n e os respetivos valores de x_1, x_2, \dots, x_n , é possível realizar uma estimativa dos parâmetros β_0 , β_1 e s^2 que representam os valores esperados do declive, da ordenada na origem e da variância. De forma a se obterem as estimativas $\widehat{\beta}_0$ e $\widehat{\beta}_1$, utiliza-se o método dos mínimos quadrados [25]. Neste método procuram-se os estimadores $\widehat{\beta}_0$ e $\widehat{\beta}_1$ que minimizam a soma dos resíduos quadrados a partir dos seus valores estimados \widehat{y}_i . Desta forma é definido um critério Q que se pretende minimizar.

$$Q = \sum_{i=1}^n \widehat{e}_i^2 = \sum_{i=1}^n (y_i - \widehat{y}_i)^2 = \sum_{i=1}^n (y_i - \widehat{\beta}_0 - \widehat{\beta}_1 x_i)^2.$$

Equação 3.13- Minimização do critério Q

De referir que os valores de \widehat{y}_i estimam $E(y_i)$ e não y_i . Para se encontrarem os valores de $\widehat{\beta}_0$ e $\widehat{\beta}_1$ que minimizam Q , procede-se a uma diferenciação com respeito a $\widehat{\beta}_0$ e $\widehat{\beta}_1$ [25].

$$\frac{\partial Q}{\partial \widehat{\beta}_0} = -2 \sum_{i=1}^n (y_i - \widehat{\beta}_0 - \widehat{\beta}_1 x_i) = 0$$

Equação 3.14 - diferenciação da equação 3.11 com respeito a $\widehat{\beta}_0$

$$\frac{\partial Q}{\partial \widehat{\beta}_1} = -2 \sum_{i=1}^n (y_i - \widehat{\beta}_0 - \widehat{\beta}_1 x_i) x_i = 0$$

Equação 3.15- diferenciação da equação 3.11 com respeito a $\widehat{\beta}_1$

Resolvendo as derivadas parciais, igualadas a zero, obtém-se as equações normais em função dos estimadores pontuais que definem o método dos mínimos quadrados.

$$\widehat{\beta}_1 = \frac{\sum_{i=1}^n x_i y_i \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{\sum_{i=1}^n x_i^2}{n}}$$

Equação 3.16- determinação do estimador $\widehat{\beta}_1$ pelo método dos mínimos quadrados

$$\widehat{\beta}_0 = \frac{1}{n} \left(\sum_{i=1}^n y_i - \sum_{i=1}^n x_i \cdot \widehat{\beta}_1 \right)$$

Equação 3.17- determinação do estimador $\widehat{\beta}_0$ pelo método dos mínimos quadrados

Resíduos

Chama-se de resíduo ao desvio entre o valor real y_i , e o seu valor estimado \widehat{y}_i , sendo este calculado da seguinte forma:

$$\widehat{e}_i = (y_i - \widehat{y}_i)$$

Equação 3.18 - Determinação do estimador dos resíduos

O símbolo \widehat{e} presente sobre o parâmetro do resíduo deve-se ao facto de que \widehat{e}_i é referido como o desvio do valor estimado de y_i em função do seu valor real, sendo um valor conhecido, enquanto que o ε_i é referido como o desvio do valor esperado $E(y_i)$ em função do valor real y_i .

Estimação da variância

A variância dos erros, σ^2 é estimada de maneira a se obter uma indicação da variabilidade da distribuição de probabilidade de y_i . Para o seu cálculo é utilizada a soma dos quadrados dos resíduos, considerando que cada y_i provem de distribuições de probabilidade com diferentes médias que dependem de x_i .

A soma dos quadrados dos resíduos, ou simplesmente SQR, é calculada pela equação 3.19.

$$SQR = \sum_{i=1}^n (y_i - \widehat{y}_i)^2$$

Equação 3.19 - Determinação da soma dos quadrados dos resíduos

Num modelo de regressão linear, a variância é estimada a partir de \hat{y}_i , que é uma estimativa de do valor esperado, ou valor médio de y_i . A equação 3.20 calcula o estimador da variância σ^2 [35].

$$\sigma^2 = \frac{SQR}{n - 2}$$

Equação 3.20 - Determinação do estimador da variância

A soma dos quadrados dos resíduos é dividida por $n - 2$ devido a existir a estimação de dois parâmetros na regressão linear.

Coeficiente de determinação e de correlação

O coeficiente de determinação, r^2 , é uma medida de ajustamento estatístico que indica a proporção de variação em y que é explicada pelo modelo, ou equivalentemente, que é explicada pela regressão de x [25]. O valor de r^2 varia entre 0 e 1 e indica o quanto o modelo consegue explicar os valores observados, ou seja, quanto maior for o valor de r^2 mais explicativo é o modelo e melhor este se ajusta à amostra. Na prática considera-se que o ajustamento é razoável quando r^2 é maior ou igual a 0.8 [35]. Este é calculado através da equação 3.21.

$$r^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})}$$

Equação 3.21 - Cálculo do coeficiente de determinação

O coeficiente de correlação indica a relação linear entre a variável x_i e a variável y_i . Este é calculado pela equação 3.22.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Equação 3.22 - Cálculo do coeficiente de correlação

Testes de hipóteses e intervalo de confiança para β_1

Na determinação e análise de um modelo de regressão linear é usual elaborar-se testes de hipóteses apenas sobre β_1 , considerando-se o facto de a principal prioridade é determinar se existe uma relação linear entre y e x [25]. De forma a se testar se existe linearidade entre as duas variáveis é considerado o seguinte teste de hipóteses: $H_0: \beta_1 = 0$, que diz não existir linearidade entre y e x . Na elaboração do teste de hipótese, é assumido que y_i é normalmente distribuído. A partir da última afirmação são definidas três propriedades, a primeira afirma que β_1 é normalmente distribuído, a segunda que $\frac{(n-2)s^2}{\sigma^2}$ tem uma distribuição Qui-quadrado, e a terceira afirma que β_1 e σ^2 são independentes [25]. A partir destas três propriedades a estatística de teste é nos dada pela equação 3.23.

$$t_{obs} = \frac{\hat{\beta}_1}{\frac{s}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim t_{n-2}$$

Equação 3.23 - Estatística de teste t

Onde s é o desvio padrão esperado, e n o número de observações, sendo $n-2$ o número de graus de liberdade.

O teste de hipóteses pode ser tanto bilateral como unilateral, embora a primeira opção seja a mais frequentemente utilizada. Em ambos os casos pretende-se rejeitar $H_0: \beta_1 = 0$ se o módulo de t_{obs} for maior que $t_{\frac{\alpha}{2}, n-2}$, onde α é o nível de significância desejado para o teste a $n - 2$ graus de liberdade. Estes valores são disponibilizados por uma tabela estatística *t-Student*.

O intervalo de confiança de $100(1 - \alpha)\%$ para β_1 , é obtido pela equação 3.24, rejeitando-se os valores que se encontrarem definidos dentro do intervalo de rejeição, $R_\alpha = \left] -\infty; t_{\frac{\alpha}{2}, n-2} \right[\cup \left] t_{\frac{\alpha}{2}, n-2}; +\infty \right[$ [35].

$$\hat{\beta}_1 \pm t_{\frac{\alpha}{2}, n-2} \frac{s}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

Equação 3.24- Determinação do intervalo de confiança para o parâmetro $\hat{\beta}_1$

Onde α representa o nível de significância utilizado no teste de hipóteses.

Similarmente ao intervalo de confiança, que nos devolve uma estimativa de um parâmetro populacional desconhecido, o intervalo de previsão estima o resultado para a determinação das amostras futuras [25].

O método é idêntico ao utilizado na determinação de um intervalo de confiança utilizando como variável dependente, o valor futuro calculado a partir da extrapolação.

$$\widehat{y_{previsto}} \pm t_{\frac{\alpha}{2}, n-2} s \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

Equação 3.25 - Determinação do intervalo de previsão

3.4 Modelos de previsão

As técnicas de previsão encontram-se intrinsecamente ligadas com o processo de tomada de decisão. As previsões são utilizadas como medidas de ajuda a agentes, ou empresas, para encontrar soluções e tomar decisões para um futuro incerto. Uma vez que erros de previsão são inevitáveis num mundo em que acontecimentos futuros são imprevisíveis, a teoria clássica sobre técnicas de previsão é formatada com a suposição de que os agentes encarregues de moldar estas técnicas, desejam minimizar os custos associados a esses erros [36].

Existem vários tipos de modelos de previsão descritos na literatura sendo que normalmente em aplicações práticas são preferidos os mais robustos. Diferentes companhias procuram otimizar modelos que permitam às empresas diagnosticar atempadamente problemas com os seus permutadores de calor, cruciais à garantia da manutenção das metas energéticas propostas.

3.4.1 Filtro de *Kalman* híbrido

Os conceitos de observadores de estado e filtros de ruído foram introduzidos na década de 60 por *Luenberger* e *Kalman*. Estes são algoritmos computacionais, desenvolvidos para estimar parâmetros que não são medidos, ou de difícil medição, devido à falta de aparelhos apropriados para os poderem estimar ou devido ao elevado custo económico de sensores *hardware*. Estes foram desenvolvidos para possibilitar a sua utilização numa vasta gama de problemas associados aos mais variados tipos de equipamentos.

Os filtros de *Kalman* são um método matemático criado por *Rudolf Kalman* com propósito de utilizar observações de grandezas ao longo do tempo, distorcidas com ruído e outros tipos de incerteza, por forma a obter resultados que tendem a se aproximar dos valores reais das observações medidas [37]. Estes filtros calculam uma média entre a predição e o valor medido, atribuindo um maior ganho aos valores com menor incerteza por forma a estes se aproximarem dos reais [37]. São modelos matemáticos

capazes de representar um sistema real pois apresentam fatores que estão presentes na realidade. Os métodos que utilizam tais princípios são chamados de métodos estocásticos [37].

O autor em *Prasad et al. (2005)* utiliza um filtro de *Kalman* híbrido. O objetivo deste filtro é de devolver uma resposta futura, enquanto é adicionado um valor de *input* passado [24]. Com a sequência de dados obtidos o filtro aproximará os valores medidos aos seus reais, utilizando de seguida a parte híbrida do filtro, a previsão desses modelos através de um diferente algoritmo [24]. O modelo continuará a prever até que um valor definido de fator de limpeza seja atingido, ou que seja parada a introdução de um *input* no modelo [24].

Em *Prasad et al. (2005)* é utilizado o fator de limpeza como medida de *performance*, que segundo o autor é considerado um método alternativo de monitorização da degradação de um permutador de calor.

A utilização do filtro de *Kalman* híbrido e dos algoritmos incorporados neste modelo de previsão são, segundo *Prasad et al. (2005)*, suficientemente robustos para lidar com a informação medida pelos sensores, e prever a *performance* do permutador com mais de 3 anos de antecedência [24].

3.4.2 Modelos de extrapolação da regressão linear

Um tipo diferente de modelo de previsão é utilizado pelos autores em *Schmitz, et al. (2011)* e em *Friebel et al. (2009)*. Estes utilizam um modelo de regressão linear para determinar o tempo de funcionamento de um permutador de calor até o seu momento de limpeza.

Em *Friebel et al. (2009)* é utilizado um modelo de previsão utilizando o histórico dos dados calculados do coeficiente global de transferência de calor, e prever o momento de limpeza do permutador de calor antes de existir uma perturbação no funcionamento do mesmo. Os autores em *Schmitz, et al. (2011)* utilizam um intervalo histórico de grande dimensão, 2900 dias, por forma o algoritmo utilizar o máximo da informação recolhida, prevendo o tempo de limpeza do permutador de calor através de duas medidas de *performance*, o coeficiente global de transferência de calor, e a eficiência térmica.

Os autores em *Schmitz, et al. (2011)* fazem referência às vantagens de se utilizar modelos que sejam mais simples e que não procurem estimar os estados internos num permutador de calor, por forma a avaliar a sua *performance*. Os modelos de regressão linear são modelos que não necessitam de treino para reter uma memória sobre os acontecimentos passados e depois prever os futuros, usando para o efeito apenas uma estimação sobre o erro obtido entre a média dos dados medidos e dos valores estimados evitando assim falhas de medição que podem ser reveladas aquando da utilização, por exemplo, de uma rede neuronal, que não consegue captar os desvios obtidos no cálculo da *performance* do permutador de calor, quando este deixa de trabalhar num estado interno dito normal [18]. Para

contornar estas desvantagens é utilizado um modelo físico mais simples utilizando dois parâmetros, a eficiência térmica e o coeficiente global de transferência de calor [18].

O algoritmo utilizado em *Schmitz, et al. (2011)*, utiliza os dados medidos para estimar o estado real do permutador de calor, a variável eficiência e a variável U . Este continua em funcionamento até que ocorra uma perturbação ou falha no processo de estimativa, de tal forma que um baixo valor de uma das variáveis seja atingido. A partir desta fase o algoritmo estima os dados futuros da *performance* térmica utilizando para o efeito a eficiência térmica e o coeficiente global de transferência de calor [18].

Após a elaboração do modelo, é utilizado um teste t para determinar a qualidade da regressão e determinar um intervalo de confiança que demonstre a incerteza da regressão [17,18]. Para além de um intervalo de confiança também é utilizado um intervalo de previsão, elaborado por forma a se observar a incerteza da extrapolação.

Este método de previsão de *performance* é referido por *Schmitz, et al. (2011)* e por *Friebel et al. (2009)* como um método robusto e de bom funcionamento para a maioria dos testes efetuados, embora exista uma dificuldade na interpretação e análise da influência de todos os *inputs* e *outputs* de temperatura, sendo utilizado o cálculo do UA e da eficiência térmica para uma maior facilidade na deteção de *fouling* [20, 36].

3.4.3 Redes Neurais

A utilização de métodos de previsão através de redes neurais é explicada em *Raeesi et al. (2014)*. Estes relacionam a previsão de uma única variável, utilizando diferentes *inputs*, que correspondem a diferentes ciclos históricos [39].

Existem diferentes métodos que podem ser modelados e utilizados em técnicas de previsão, e as redes neurais são das mais utilizadas ao longo das últimas décadas [39]. As redes neurais são modelos que surgiram originalmente na década de 1940, como tentativa de reprodução do cérebro humano. Estes podem ser utilizados numa vasta gama de aplicações desde as telecomunicações ao imobiliário [40]. Nesta dissertação as redes neurais serão adaptadas ao tema proposto, focando-se na sua capacidade de previsão pelo conhecimento adquirido a partir dos dados passados.

Estas redes são modelos úteis na tarefa de reconhecimento de tendências e de relações presentes em séries de dados [39]. A rede significa uma coleção de estruturas simples que interligadas entre si criam um sistema complexo, enquanto que a parte neuronal refere-se à simulação das sinapses cerebrais através de funções presentes em nodos chamados de neurónios [39].

Na resolução de diferentes problemas, existe uma vasta gama de redes neurais que podem ser utilizados. Na tarefa de previsão as redes mais utilizadas são as chamadas de *feed forward neural network*,

redes neuronais pró-alimentadas, e estas são treinadas com o objetivo de produzirem um *output* com o menor desvio possível em relação ao verdadeiro valor das séries [39]. Este tipo de redes neuronais é composto por diferentes nodos, ou neurónios, que se encontram interligados a dois outros conjuntos de nodos, os de entrada e os de saída. Os nodos de entrada são utilizados para receber a informação passada, e os nodos de saída utilizados para devolverem os valores previstos pela rede neuronal. Neste tipo de redes neuronais a informação flui apenas numa direção [39].

Na literatura *Raeesi et al. (2014)* utiliza a rede neuronal pró-alimentada com 6 nodos de entrada utilizando a informação obtida entre diferentes dias equidistantes de uma semana, considerando que em cada um desses dias a informação observada em determinado dia, terá comportamento semelhante na semana anterior e assim sucessivamente [39]. No desenvolvimento deste método 80% da informação é utilizada como treino da rede, e 20% utilizada para a fase de testes [39]. O treino de memória à rede é elaborado por minimização do erro médio quadrático obtido em cada fase de treino [39].

Neurónios artificiais

Uma rede neuronal artificial consiste essencialmente num conjunto simulado de unidades de processamento simples, que comunicam entre si enviando sinais através de um elevado número de conexões [40].

A descrição de um neurónio artificial pode ser feita por uma equação matemática simples que calcula o valor de saída em função dos valores de entrada. Associado a cada valor de entrada, *input*, existe um valor w_i , peso de ligação, que formam a activação do neurónio. Esta é transformada por uma função de ativação, $f(a)$, que permite a obtenção do valor de saída, *output* [40]. O *bias*, b , permite que se adquirem valores de saída não nulas, e é caracterizado pelo ruído inerente nas observações.

Os pesos de ligação são multiplicados pelas saídas dos neurónios anteriores fornecendo o valor do neurónio posterior, como se pode observar na figura 3.6. Para cada neurónio anterior existe um peso de ligação, que somados resultam num neurónio seguinte. Estes cálculos são efetuados para todos os neurónios que se encontrem a jusante dos anteriores na rede neuronal. Desta forma os pesos de ligação funcionam como graus de determinação entre dois neurónios artificiais.




Figura 3.6 - Esquematisação de uma rede neuronal

$$y_1 = b_1^{(2)} + w_{11}^{(2)} f + w_{21}^{(2)} f + w_{31}^{(2)} f$$

$$y_2 = b_2^{(2)} + w_{12}^{(2)} f + w_{22}^{(2)} f + w_{32}^{(2)} f$$

Equação 3.26 - Somatório do produto entre os pesos de ligação e a função de ativação

Onde o índice “(2)” representa a ligação entre a camada escondida e a camada de saída, $b_1^{(2)}$ representa o *bias*, $w_{21}^{(2)}$ representa o peso de ligação e f representa a função de ativação.

Os neurónios das camadas ocultas são os que armazenam a informação de forma a iniciar o seu real processamento. Estes extraem a informação da camada de input, e identificam padrões nessa informação que subsequentemente são transmitidos às camadas posteriores. Como já referido anteriormente, após estes receberem a informação são ativados através de uma função de ativação.

Funções de ativação

No mundo biológico a função de ativação acumula informação no interior do núcleo de cada neurónio, e quando a quantidade de informação acumulada atinge um determinado limite o neurónio é ativado e emite um impulso eletroquímico para os neurónios vizinhos. O estado de cada neurónio pode ser representado por uma variável binária, 0 ou 1, não existindo estados intermédios.

No caso do neurónio artificial pode-se apresentar estados intermédios. Se for possível considerar uma função de ativação que não assuma apenas os valores de 0 e 1 o tratamento matemático torna-se de certa forma mais facilitado.

As funções de ativação determinam o nível de transformação de um neurónio perante as suas entradas, existindo diferentes tipos de funções sendo as principais e mais utilizados nas redes neuronais de tipo

feedforward, ou pró-alimentada. Este tipo de rede neuronal, propaga os valores de *input* ao longo da rede neuronal até à camada de saída. As funções mais utilizadas neste tipo de rede neuronal são a função sigmoide representada na equação 3.27, e a função tangente hiperbólica representada na equação 3.28.

Função Sigmoide

$$f(x) = \frac{1}{1 + e^{-x}}, \quad x \in \mathbb{R}$$

Equação 3.27 - Função de ativação sigmoide

Função tangente hiperbólica

$$f(x) = \tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

Equação 3.28 - Função de ativação tangente hiperbólica

Após determinação da arquitetura da rede, a próxima etapa passa pela determinação dos parâmetros, peso de ligação e *bias*, que determinem os valores previstos com o menor erro possível. Este processo chama-se de treino, sendo o algoritmo de retro propagação, ou *backpropagation*, o mais utilizado numa rede neuronal do tipo *feedforward*, ou pró-alimentada.

O algoritmo de *backpropagation* passa por encontrar os valores dos parâmetros que permitem minimizar uma determinada função de erro através do método gradiente descendente. A função de erro é calculada pela média do erro quadrático como demonstrado na equação 3.29.

$$E = \frac{1}{n} \sum_t (T_t - Y_t)^2$$

Equação 3.29 - determinação do erro médio quadrático

onde n representa o número de pontos utilizados no treino, T_t os valores de *input* e Y_t os valores de *output*.

No algoritmo de retro propagação pretende-se alterar os parâmetros de forma proporcional ao simétrico da deriva da função de erro, em ordem a cada parâmetro. Durante o treino da rede este funciona em três fases. Primeiro o sinal à entrada de cada neurónio, nas diferentes camadas, é propagado pela rede até se obter a resposta produzida pela camada de saída. Em seguida, a resposta obtida à saída é comparada à desejada calculando-se a função do erro médio. Por último pretende-se a minimização do erro quadrado médio obtido, que é efetuada retro propagando-se o mesmo pela rede por forma a ajustar os parâmetros, pesos de ligação e *bias*, produzindo-se a resposta desejada.

Os resultados obtidos para este tipo de previsão são aceitáveis de acordo com as conclusões verificadas na literatura, sendo o número de neurónios e o tipo de função de ativação utilizados os principais parâmetros que influenciam a diminuição do erro na rede neuronal [37, 38].

4 O modelo de estimação e de previsão

Os modelos de previsão e tratamento de dados foram implementados usando a ferramenta *Microsoft Excel* e a funcionalidade do *Visual Basic for Applications (VBA)*.

4.1 Obtenção dos dados relativos às variáveis

Os dados foram recolhidos através do *software*, *Aspen Process Explorer* que funciona como base de dados de todas as variáveis medidas em linha na refinaria. A sua recolha foi elaborada através do *software* para a implementação dos modelos de previsão, o *Microsoft Office Excel*.

Os permutadores de calor foram cuidadosamente mapeados com o objetivo de facilitar a observação das variáveis medidas em linha. Estas serão utilizadas para quantificar os valores de eficiência térmica e para estudar a formação de incrustações e as variações nas condições processuais da unidade e da fábrica.

As *tag's* funcionam como uma etiqueta atribuída a cada variável medida em linha. Elas são encontradas através da utilização do sistema de controlo *DCS* da refinaria.

A figura 4.1 mostra-nos um exemplo de utilização do sistema de controlo *DCS*.

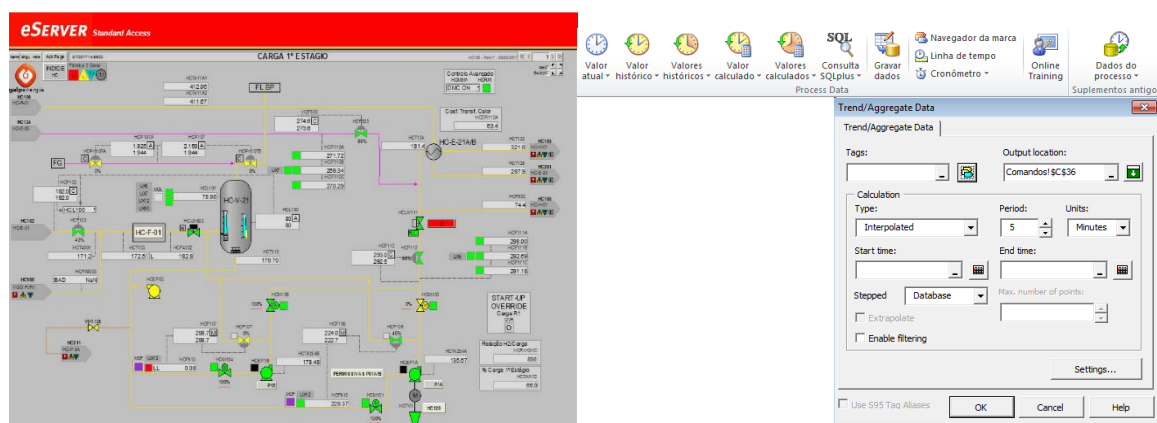


Figura 4.1 - interface do sistema DCS à esquerda, utilização do Aspen Process Explorer a partir do Excel à direita

Para consulta da base de dados existem uma série de parâmetros que se podem definir, tal como método de obtenção de valores, o período de análise e o intervalo entre pontos. Foi criada uma sub-rotina em *VBA* para automatizar o processo de consulta da base de dados.

Para facilitar a consulta da base de dados foi criada uma interface gráfica em *Excel* utilizando *User forms* e botões de comando, ver a figura 4.3. Na construção da interface gráfica foi tido em consideração que esta será usada por pessoas com diferentes graus e áreas de formação pelo que ela tem de ser “*User friendly*” e permitir um acesso rápido e fácil às funcionalidades desejadas. Para que o acesso seja facilitado foram definidas por defeito valores para todos os parâmetros e *tag's* de consulta. A utilização do *software* necessita apenas que sejam definidas as datas de início e fim da consulta. Esta estratégia implica a elaboração de uma folha por permutador. O período de consulta foi definido para ser de 12 em 12 horas.

Para cada permutador de calor existem *tag's* associadas às suas variáveis, mas nem todos têm a informação necessária disponível de forma clara e evidente relativamente às variáveis de caudal. Na tabela 4.1 encontram-se as *tag's* e os pressupostos tidos em consideração para que o processo de obtenção destas variáveis fosse o mais preciso possível.

Tabela 4.1 - *Tag's* para obtenção das variáveis temperatura e caudal de cada permutador

	HC-E-21	HC-E-22	HC-E-24	HC-E-25	HC-E-31	HC-E-46
Temperatura entrada tubular	HCT124_DACA (leitura direta)	HCT172_DACA (leitura direta)	HCT261_DACA (leitura direta)	HCT502_DACA (leitura direta)	HCT404_DACA (leitura direta)	HCT660_DACA (leitura direta)
Temperatura entrada corpo	HCT411A1 (leitura direta)	HCT214A (leitura direta)	HCT259_DACA (leitura direta)	HCT243_DACA (leitura direta)	HCT313_DACA (leitura direta)	HCT262_DACA (leitura direta)
Temperatura saída tubular	HCT123_DACA (leitura direta)	HCT174_DACA (leitura direta)	HCT258_DACA (leitura direta)	HCT217_DACA (leitura direta)	HCT335A_DACA (leitura direta)	HCT661_DACA (leitura direta)
Temperatura saída corpo	HCT125_DACA (leitura direta)	HCT173_DACA (leitura direta)	HCT260_DACA (leitura direta)	HCT218_DACA (leitura direta)	HCT103_DACA (leitura direta)	HCT663_DACA (leitura direta)
Caudal de entrada tubular	HCF112_DACA, HCF503_DACA (leitura direta)	HCF123_DACA, HCF544_DACA (leitura direta)	HCF112_DACA, HCF503_DACA, HCF123_DACA, HCF544_DACA + <i>Quench's</i> (soma 2 reatores)	HCF112_DACA, HCF503_DACA, HCF123_DACA, HCF544_DACA + <i>Quench's</i> (soma 2 reatores)	HCF922_DACA (leitura na bomba HC-P-06)	HCF919, HCF120_DACA, HCF918 (média dos sensores)
Caudal entrada corpo	HCF112_DACA, HCF503_DACA, + <i>Quench's</i> (leitura direta)	HCF123_DACA, HCF544_DACA, + <i>Quench's</i> (leitura direta)	HCF161_DACA (leitura saída da HC-V-03)	HCF143_DACA (leitura saída da HC-V-25)	ORFI5107 (leitura na saída da armazenagem)	HCF161_DACA (leitura saída da HC-V-03)

4.2 Funções aplicadas aos modelos

Para calcular a eficiência dos permutadores foi necessário construir funções em VBA para garantir uniformidade de unidades.

4.2.1 Função de conversão de caudais volumétricos para mássicos

Esta função tem como objetivo converter as unidades dos caudais de hidrogénio provenientes da base de dados. Estes são medidas em kNm^3 , quilo normais metros cúbicos, ou apenas em Nm^3 . Isto deve-se ao facto do hidrogénio, como os outros gases ideais, ser facilmente compressível causando alterações no seu volume enquanto movimentado no processo fabril. As condições assumidas para este estado dito “normal” são as utilizadas na refinaria, que considera uma pressão de 1.013 bar, temperatura de 15°C e 0% de humidade relativa. Uma mol de gás ideal ocupa $23.645 dm^3$ de volume. É utilizada a equação 4.1 para determinar esse valor.

$$M(kg) = V \cdot \frac{MM}{23.645 \left(\frac{kmol}{Nm^3} \right)}$$

Equação 4.1 - Conversão de normais metros cúbicos para Kg

Onde M representa a massa em quilogramas, V o volume em Nm^3 e MM a massa molar em $kmol/kg$.

Esta função usa o seguinte pseudocódigo.

```
Função Flow_Kg (caudal_H2)
  Se caudal_H2 < 1000 Então
    Flow_Kg = (caudal_H2 * 2 * 1000)/23.645
  Senão
    Flow_Kg = (caudal_H2 * 2)/23.645
  Fim Se
Fim da Função
```

Os permutadores de calor que necessitam de ter esta função incorporada no seu modelo são, o HC-E-21, HC-E-22, HC-E-24, HC-E-25 e HC-E-46.

4.2.2 Função de determinação da C_{min} , e do rácio entre taxas

Relativamente às capacidades caloríficas, não existe maneira fiável e direta de serem determinadas nas correntes no processo fabril da refinaria devido à incerteza da sua composição e às flutuações de temperatura. Desta forma as capacidades caloríficas foram determinadas por métodos de regressão através dos dados disponibilizados pelo licenciador de cada um dos equipamentos.

As capacidades caloríficas e as densidades foram calculadas usando a temperatura de entrada no permutador porque todos os sensores se encontram a montante. A partir destas variáveis determina-se a taxa mínima de capacidade calorífica necessária ao cálculo da eficiência térmica. Esta função é chamada para todos os permutadores para identificar qual dos fluidos garante a taxa mínima. Esta função também calcula as densidades em função da temperatura assumindo os mesmos pressupostos que foram usados no cálculo das capacidades caloríficas. O pseudocódigo da função é o seguinte.

```
Função Cmin (temp_ent_tubular, temp_ent_Corpo, caudal_tubular,
caudal_corpo)
'Neste código são adicionados alguns parâmetros das regressões, para
determinação da capacidade calorífica e da densidade para cada um dos
caudais. Não são apresentados neste pseudocódigo.
Parâmetros: cp_tubular e densidade_tubular, cp_corpo, densidade_corpo
Se caudal_tubular * cp_tubular * densidade_tubular <
    caudal_corpo * cp_corpo * densidade_corpo Então
    Cmin = caudal_tubular * cp_tubular * densidade_tubular
Senão
    Cmin = caudal_corpo * cp_corpo * densidade_corpo
Fim Se
Fim da Função
```

A função *Crácio* permite calcular o rácio entre as taxas de capacidade calorífica, mínima e máxima, por forma a ser chamada pela função que calcula o coeficiente global de transferência de calor, função *U*.

```
Função Crácio (temp_ent_tubular, temp_ent_corpo, caudal_tubular,
caudal_corpo)
'Neste código são adicionados alguns parâmetros das regressões, para
determinação da capacidade calorífica e da densidade para cada um dos
caudais. Não são apresentados neste pseudocódigo.
Parâmetros: cp_tubular e densidade_tubular, cp_corpo, densidade_corpo
Se caudal_tubular * cp_tubular * densidade_tubular <
    caudal_corpo * cp_corpo * densidade_corpo Então
    Cmax = caudal_corpo * cp_corpo * densidade_corpo
Senão
    Cmax = caudal_tubular * cp_tubular * densidade_tubular
Fim Se
Fim da Função
```

4.2.3 Função de eficiência térmica

A função *Eficiência* permite calcular a eficiência térmica dos permutadores de calor utilizando para tal as temperaturas à entrada e saída, do permutador e os caudais do corpo e do tubular.

```
Função Eficiência (temp_ent_tubular, temp_sai_tubular, temp_ent_corpo,
temp_sai_corpo, caudal_tubular, caudal_corpo)
    Parâmetros: cp_tubular e densidade_tubular, cp_corpo, densidade_corpo
    Se Cmin = caudal_tubular * cp_tubular * densidade_tubular Então
        Eficiência = (temp_sai_tubular -
temp_ent_tubular)/(temp_ent_corpo - temp_ent_tubular)
    Senão
        Eficiência = (temp_ent_corpo -
temp_sai_corpo)/(temp_ent_corpo - temp_ent_tubular)
    Fim se
Fim da Função
```

4.2.4 Função do coeficiente global de transferência de calor

O coeficiente global de transferência de calor é calculado, nesta função, a partir do método NTU- ϵ , utilizando para o efeito a eficiência térmica calculada anteriormente. Para além da função de eficiência térmica ela também utiliza a função *Crácio* entre taxas de capacidade calorífica, parâmetro indispensável à determinação do coeficiente de transferência de calor como referenciado no capítulo anterior. Esta função é utilizada em todos os permutadores de calor, e existe uma específica para cada um deles devido à utilização da área de transferência disponibilizada pelo licenciador da fábrica.

```
Função U ( temp_ent_tubular, temp_sai_tubular, temp_ent_corpo,
temp_sai_corpo, caudal_tubular, caudal_corpo, area)
    U = ((Crácio - 1)*log((eficiência - 1)/(eficiência * Crácio -
1)))/area
Fim da Função
```

4.3 Implementação do tratamento de dados

Os dados medidos na fábrica são sujeitos a um certo tipo de ruído que baixa a confiança dos dados obtidos, e em adição a esse problema existe por vezes falhas nos equipamentos de medição que produzem erros, ou *outliers*, que geram um efeito negativo sobre a qualidade da estimação dos parâmetros, que por sua vez afeta a qualidade de previsão.

Para melhorar a *performance* dos algoritmos de estimação foram desenvolvidos algoritmos para eliminar os *outliers*, por forma a corrigir falhas de medição e para eliminar dados. Estas funções pretendem eliminar os componentes de altas frequências, deixando as baixas frequências características do processo de *fouling*, da evolução da eficiência térmica e das *NTU*.

4.3.1 Eliminação de dados

Esta é a primeira etapa do modelo, e tem como objetivo a identificação e eliminação de medições consideradas indesejadas para a estimação dos parâmetros da regressão. Este método tem em consideração todos os dados extraídos da base de dados para o intervalo de tempo pretendido, e identifica um intervalo de confiança à média populacional de cada variável utilizada para a determinação da eficiência térmica. Foi considerado um intervalo de confiança de 95%, este algoritmo seleciona todos os dados que se encontrem abaixo do seu limite inferior e exclui-os da série temporal.

Para além duma estimativa pontual de um parâmetro é, em muitas situações, importante dispor de alguma forma de intervalo que indique a confiança que se pode depositar na estimativa pontual [41].

Considerando uma amostra aleatória simples X_1, \dots, X_n obtida a partir de uma população que apresente uma distribuição normal, com média μ e variância σ^2 conhecida. Desta forma a distribuição amostral da média também é normal obtendo-se a equação 4.2, onde a variável Z tem uma distribuição normal padronizada [41].

$$Z = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0,1)$$

Equação 4.2 - Determinação do valor Z com distribuição normal

O intervalo de confiança para a média populacional é dado pela equação 4.3.

$$IC(\mu, 1 - \alpha) = \left(\bar{X} - Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}; \bar{X} + Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right)$$

Equação 4.3 - Intervalo de confiança para a média populacional

O pseudocódigo deste algoritmo é em baixo descrito.

Procedimento Eliminação de dados

```
Para i=0 Até Linha final
' a corresponde ao parâmetro declive, b parâmetro B0, est ao valor
estimado obtido, IC ao intervalo de confiança. n corresponde ao número de
observações
    a = função_Excel_Slope(Tempo, Variável)
    b = (soma(variável)/ n) - ((soma(tempo)/ n)* a)
    est_Variável = a + b * tempo
    Limite_Variável = raizQ ( 1 / (n - 1) *
Soma_erros_Variável
    IC_Variável = Variável_Média -
função_Excel_teste_t(nível significância, n.g.l.) *
Limite_Variável
i Seguinte
Para i = 0 Até Linha final
    Se Variável < IC_Variável Então
        Variável = " "
    Fim Se
i Seguinte
Fim procedimento
```

4.3.2 Correção das falhas de medição

As falhas de medição são um problema comum na obtenção de dados a tempo real em equipamentos de uma refinaria. Este algoritmo estima os parâmetros para a série temporal de cada variável, e substitui os valores em falta pelos estimados. No caso da incorporação de dados relativos a paragens gerais, é possível observarem-se retas fora da tendência da série temporal, que correspondem aos valores estimados anteriormente e repostos no lugar dos eliminados pelo algoritmo precedente.

Procedimento Reposição de dados

```
' est_Variável corresponde aos valores estimados no procedimento anterior
GLOBAL: est_variável
Se Variável = " " Então
    Variável = est_variável
Fim Se
Fim Procedimento
```

4.3.3 Remoção dos Outliers

O termo anglo saxónico *outlier*, refere-se aos pontos de extrema irregularidade que ocorrem num curto período de tempo na série temporal. Estes são os valores medidos por falhas ocasionais nos

equipamentos de medição, ou por acontecimentos externos ao processo do equipamento, como lavagens ou paragens, que não foram excluídos na etapa de eliminação de dados.

Embora esta etapa seja efetuada normalmente em processos estacionários, a utilização das médias móveis permite contornar o problema de forma eficaz. O termo “móvel” deste filtro refere-se à capacidade de o algoritmo proceder à eliminação de *outliers* dos dados num processo não estacionário. Na modelação deste algoritmo foram utilizados poucos pontos para o efeito por forma a não remover as tendências da série temporal, nem o seu ruído, sendo este último tratado, no passo seguinte.

Procedimento Filtragem Média móvel

' Offset permite fazer avançar uma observação a cada cálculo efetuado, até se atingir a observação pretendida.

Para i = 0 Até Linha final

 filtro_Variável = média (offset (Observação_1);

 offset(Observação_(1 + n)))

 i Seguinte

Fim Procedimento

4.3.4 Redução do ruído de medição

O ruído é composto por componentes de altas frequências superiores às componentes de baixas frequências que caracterizam a diminuição do ruído do processo. Para que seja possível remover as altas frequências mantendo as componentes de baixa frequência, é utilizado um filtro passa baixo que permite suavizar os dados mantendo as tendências relevantes que contêm informação importante sobre o processo.

Neste algoritmo é utilizado o método de filtragem por mínimos quadrados. Nesta modelação existe um *lag* associado à filtragem dos dados que correspondem à dimensão da janela usada. Este algoritmo estima os parâmetros de regressão pelo método dos mínimos quadrados, para os k pontos definidos no botão de comando da previsão presente na interface do modelo, e devolve o último valor da mesma num processo não estacionário. Este mecanismo é repetido adicionando uma nova observação e esquecendo a mais antiga até que a data final inserida aquando da obtenção das variáveis, seja atingida devolvendo uma série temporal com uma tendência suave e com uma maior aproximação aos seus valores reais. O pseudocódigo desta rotina encontra-se descrito em baixo, e a figura 4.2 ilustra o funcionamento do filtro.

Procedimento Filtragem mínimos quadrados

'eficiência_FMM, representa a eficiência filtrada por médias móveis;
eficiência_FMQ, representa a eficiência filtrada por mínimos quadrados; n
corresponde aos pontos utilizados na filtragem.

```
Se eficiência_FMM = 0 Então
    eficiência_FMQ = 0
Senão
    a = função_Excel_declive (offset(tempo),
offset(eficiência_FMM))
    b = (soma(eficiência_FMM)/n) - ((soma(tempo)/ n)* a)
    est = b + a * tempo
Fim Se
Fim procedimento
```




Figura 4.2 - Atuação do filtro de mínimos quadrados

4.3.5 Definição do valor de U limpo

O valor de U limpo é calculado com objetivo de determinar o coeficiente de limpeza da série temporal. O modelo para esta definição foi criado com base nas datas das paragens, definindo o valor obtido a um tempo específico como o primeiro dado atribuindo a esse U uma cotação de 100%.

Devido ao atraso presente na eliminação do ruído e na remoção de *outliers* como verificado anteriormente, acrescentou-se um intervalo de tempo que corresponde à correção desse desfasamento temporal.

4.3.6 Fator de limpeza

Este método é implementado no modelo com o objetivo de confirmar os valores calculados e estimados através do modelo de eficiência térmica. Este é o método utilizado no acompanhamento dos permutadores de calor na refinaria, que utiliza o quociente entre o U limpo, e o U ao longo do tempo no permutador como demonstrado anteriormente.

4.4 Implementação do modelo de previsão

O objetivo do modelo de previsão foi a implementação de um algoritmo que utilize os valores de eficiência térmica coletados e tratados ao longo do tempo, por forma a extrapolar o comportamento futuro da série temporal. Foram aplicados modelos lineares usando a regressão linear simples, e modelos não lineares utilizando a rede neuronal.

No caso da regressão simples o modelo foi elaborado para conter várias datas distintas de previsão por forma a atribuir uma maior flexibilidade na previsão dos comportamentos futuros dos permutadores de calor.

O modelo de previsão é robusto e compacto e atua apenas com um botão de comando, que permite correr diferentes algoritmos ao mesmo tempo. O modelo é dividido por um algoritmo de filtragem de mínimos quadrados, um algoritmo de estimação por regressão linear simples, um de extrapolação da regressão, outro de determinação das inferências estatísticas da regressão e da extrapolação, e por fim um algoritmo de determinação de indicadores de confiança.

4.4.1 Algoritmo de estimação

O algoritmo de estimação foi modelado de forma a funcionar como janelas de regressão ao longo da série temporal. O mecanismo é idêntico ao utilizado na filtragem por mínimos quadrados, traçando sucessivas regressões sempre que um novo dado tratado é adicionado. Isto permite estimar os parâmetros da regressão através do método dos mínimos quadrados, analisando os valores de β_1 para cada uma das regressões efetuadas observando as tendências históricas da série, e obter os dados pretendidos para se extrapolar e, portanto, prever o comportamento futuro da mesma.

Foi ainda implementado um algoritmo que permite utilizar declives com decaimentos negativos, evitando assim que o modelo extrapole uma regressão com tendência positiva. Este algoritmo é

essencialmente um método de retro propagação, verificando os valores de β_1 para toda a sequência de k pontos utilizados na regressão, memorizando apenas os declives negativos calculando de seguida a sua média. Pretende-se desta forma evitar que o modelo execute projeções onde o valor de eficiência cresça, fenómeno que seria considerado irrealista na previsão destes valores a longo prazo.

Procedimento Janelas de regressão

'eficiência_Regressão, representa a eficiência estimada que será utilizada na extrapolação; eficiência_FMQ, representa a eficiência filtrada por mínimos quadrados; n corresponde aos pontos utilizados na filtragem.

Se eficiência_FMQ = 0 **Então**

 eficiência_Regressão = 0

Senão

 a = função_Excel_declive (offset(tempo),
offset(eficiência_FMQ))

 b = (soma(eficiência_FMQ)/ n) - ((soma(tempo)/ n)* a)

 est = b + a * tempo

Fim se

Fim procedimento

4.4.2 O algoritmo de previsão

O algoritmo de previsão utiliza a técnica de extrapolação da regressão linear simples para prever os dados de eficiência térmica. Os valores futuros são determinados através do último declive calculado na estimação dos dados filtrados se o valor for negativo. Caso o declive seja positivo, o algoritmo utilizará a média dos declives através do algoritmo anteriormente detalhado.

Procedimento Modelo de previsão

' b e a são os calculados no procedimento de janelas de regressão. neg corresponde ao algoritmo negativo caso a seja positivo.

GLOBAL: a 'indica o declive calculado nas janelas de regressão

Se a > 0 **Então**

'calcula-se algoritmo que vá encontrar um de clive negativo. médiaSe calcula, para um certo número de a presentes na folha de *Excel*, apenas os declives negativos.

 neg = médiaSe (a ('para o tempo escolhido na previsão); se for
< 0)

 previsão = b + a * Tempo_futuro

Fim Se

Fim procedimento

4.4.3 Inferências estatísticas e identificação dos indicadores

Após os algoritmos de filtragem e de previsão terminarem os seus cálculos, o modelo irá ativar um conjunto de funções que permitem calcular com base nos resultados obtidos, as inferências estatísticas correspondentes à estimação através da regressão linear e respetiva extrapolação.

Neste algoritmo são calculados os erros quadráticos, o valor do teste t , os intervalos de confiança, o desvio padrão, a variância, o coeficiente de determinação e o coeficiente de correlação para a estimação da regressão, e os intervalos de previsão para a extrapolação.

É calculada a confiança da estimativa a partir dos parâmetros estatísticos calculados anteriormente e que permitem classificar a qualidade da previsão efetuada. O código completo das inferências encontra-se no Anexo IV.

4.4.4 Implementação da rede neuronal

Foi implementada em VBA, usando *ActiveX*, uma rede neuronal com 9 neurónios escondidos 3 neurónios de entrada e 1 neurónio de saída.

Solver

A ferramenta *Solver* apresenta-se de extrema utilidade aquando da resolução de problemas de programação linear, e não linear em *Microsoft Excel*. Esta disponibiliza formas de restringir um valor significativo de variáveis, até cerca de 200.

No interesse desta dissertação, a ferramenta *Solver* é utilizada como mecanismo de minimização do erro quadrático médio obtido na modulação e treino da rede neuronal. Neste podem ser definidos diferentes parâmetros que possibilitam a resolução de derivadas parciais, por meio de iterações possibilitando aplicar, embora de forma menos precisa, o algoritmo de retro propagação. A seguir serão apresentados os códigos e a construção do modelo em *Microsoft Excel*.

Procedimento Rede Neuronal

' Função solver utilizada para otimização do erro quadrático médio.
obter_dados é uma macro utilizada na recolha dos dados filtrados
calculados no modelo linear, para as fases de treino, validação e teste.

Run_NN = obter_dados

restrições: Celula objetivo $\neq 0$

treino1 = função_Solver (cel_objetivo_pesos, cel_objetivo_bias,
min_EQM)

treino2 = função_Solver (cel_objetivo_pesos, cel_objetivo_bias,
min_EQM)

treino3 = função_Solver (cel_objetivo_pesos, cel_objetivo_bias,
min_EQM)

```

validação = função_Solver (cel_objetivo_pesos, cel_objetivo_bias,
min_EQM)
teste = função_Solver (cel_objetivo_pesos, cel_objetivo_bias,
min_EQM)
Fim Procedimento

```

4.4.5 Funcionamento do modelo

Após a modelação e implementação dos modelos de previsão foi elaborado um manual de utilização geral para cada permutador de calor. Este não varia de permutador para permutador, excetuando o HC-E-21 devido à existência de a rede neuronal para além do modelo linear. A interface é idêntica para cada um deles e foi elaborada por forma a permitir a sua fácil utilização como se pode observar pela figura 4.3.

Definição da série temporal

Data inicial: 27-04-2014 00:00:00
Data final: 07-08-2017 12:00:00
Data de última paragem: 01-06-2016

Definir U Limpo Fator de Limpeza

Valor do U limpo definido (Kcal/h.m².°C): 195,10
Obter valor atual de eficiência: 60,16%

Tratamento de dados

Obter dados de temperatura
Tratamento de Dados
Obter dados de caudal

Indicadores de eficiência térmica

Nível de eficiência baixo: 07-08-2017
Nível de eficiência muito baixo: 30-10-2017

Indicadores de Confiança da regressão e previsão

Decive utilizado	-1,03E-04	
Variância e desvio padrão	0,0039%	0,62%
R2 e R da regressão de extrapolação	15,25%	39,65%
t-value	8,00	
Grau de confiança da interpolação (IC 95%)	bom relação linear	
Grau de confiança do declive	Grau de confiança baixo	
Limite inferior do declive	4,43E-05	diff. Declives -1,26E-05
Limite superior do declive	5,69E-05	
Limite inferior intervalo de previsão	58,76%	
Limite superior intervalo de previsão	61,30%	
Grau de confiança do intervalo de previsão	baixo grau de confiança	

Comandos de Estimação e Previsão

Previsão por Regressão Linear simples: Estimação/Previsão
Previsão por Rede Neuronal: Caixa rede Neuronal, Corrigir erros

Comandos para obtenção de gráficos

Apresentar gráfico previsão linear
Apresentar gráfico Rede neuronal
Gráfico Suavizado com Previsão Linear
Gráfico Suavizado com Previsão por Rede Neuronal

Comandos de Utilização

Apagar Estimação
Apagar todos os dados

Figura 4.3 - Interface do modelo linear e da rede neuronal para o permutador HC-E-21

Para ilustrar o esquema de funcionamento do modelo foi elaborado um fluxograma, presente na figura 4.4 que demonstra o mecanismo do mesmo utilizando os botões de comando representados na interface.

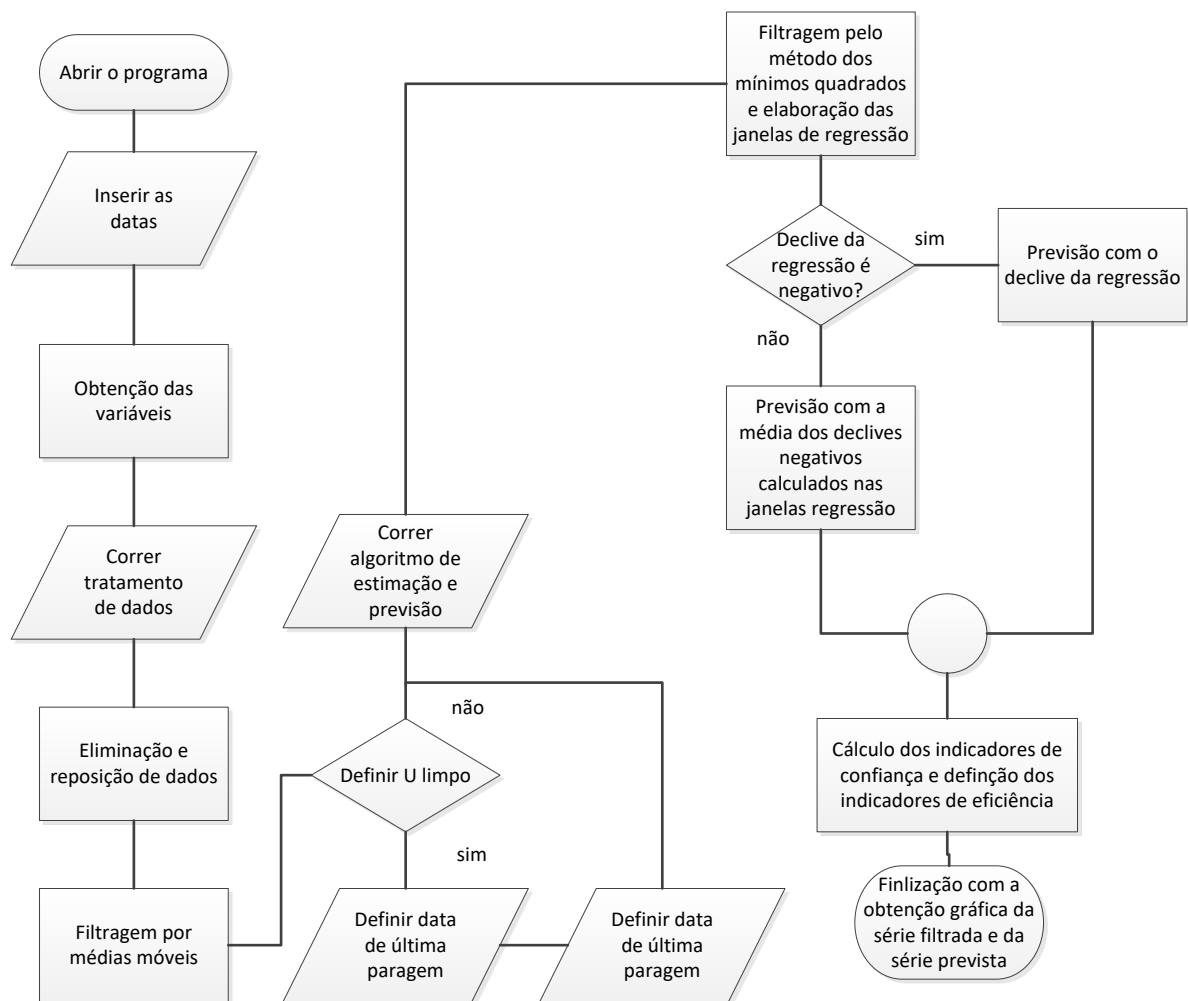


Figura 4.4 - Fluxograma do modelo linear

5 Discussão dos resultados obtidos

5.1 Determinação das propriedades físicas dos fluídos

As propriedades físicas dos fluídos foram determinadas com base nas folhas de especificação de cada permutador de calor disponibilizadas pelo licenciador da fábrica 3. A dificuldade na determinação da composição de cada corrente não permite a elaboração de um cálculo preciso destas propriedades, tendo sido utilizadas estimativas para a sua determinação.

As estimativas utilizadas para as diferentes correntes foram calculadas com base nos dados apresentados pelo licenciador em função das diferentes temperaturas disponibilizadas. Relacionando-se a fração de vapor com as capacidades caloríficas e as densidades, as propriedades físicas foram determinadas em função dos diferentes perfis de temperatura de entrada disponíveis para cada permutador de calor.

Utilizando como exemplo o permutador de calor HC-E-21, verificou-se anteriormente que este procede à troca calorífica entre a corrente de carga ao reator de *Hydrocracking*, e o efluente do mesmo. Para se determinar a massa em kg/h foi necessário estimar a densidade de cada corrente e capacidades caloríficas para determinação do calor trocado.

Depois de retirados os dados da fração de vapor nos tubos e no corpo para cada permutador, estimou-se a capacidade calorífica e densidades. Foram usados os dados disponibilizados pelo licenciador para interpolar as propriedades das correntes em função da temperatura. No caso da mistura de fases considerou-se que o valor das propriedades era dado pela soma pesada de cada fase. A figura 5.1 mostra um exemplo de estimação da fração de vapor em função do perfil de temperaturas.




Figura 5.1 - Fração de vapor em função das temperaturas de entrada no permutador HC-E-21. Dados disponibilizados pelo licenciador

A estimação da fração de vapor em função da temperatura apresenta um bom ajuste aos dados obtidos a partir da folha de especificação, garantindo uma aproximação aos valores teóricos de gás e líquido que passam por este equipamento.

Após a determinação da fração de vapor, foi possível determinar a densidade média através da equação 5.1 estimando-se a mesma em função do perfil de temperaturas de entrada.

$$\rho_{\text{médio}} = \sum \rho_i \cdot \frac{V_i}{V}$$

Equação 5.1 - Cálculo da densidade média

A capacidade calorífica média, foi determinada da mesma forma que a densidade média, como demonstrado na equação 5.2 e estimada nas mesmas circunstâncias que a densidade. Os dados obtidos nos cálculos das propriedades físicas podem ser encontrados no Anexo I.

$$cp_{\text{médio}} = f_{\text{vapor}} \cdot cp_{\text{vapor}} + (1 - f_{\text{vapor}}) \cdot cp_{\text{líquido}}$$

Equação 5.2 - Cálculo da capacidade calorífica média

5.2 Definição das eficiências ótimas

As eficiências térmicas ótimas foram determinadas com o intuito de criar indicadores que possibilitem ao utilizador dos modelos verificar quando a eficiência térmica se encontra a níveis mais baixos daqueles pretendidos, através de uma análise e caracterização histórica destes valores, e com o auxílio dos operadores da fábrica 3. Esta análise baseou-se nos valores de projeto de cada permutador de calor, e no seu comportamento entre paragens e *shut down* que permitiram determinar os indicadores de baixa eficiência.

5.2.1 Histórico de Paragens

Devido à interação entre os diferentes equipamentos e os permutadores de calor, e consequentemente a sua influência sobre a *performance* térmica, foi necessário elaborar um registo sobre todas as mudanças efetuadas ao processo que tenham tido impacto sobre os equipamentos posicionados na linha dos permutadores como mostra a tabela 5.1. Esta observação permite perceber as alterações que têm impacto direto sobre o permutador de calor, de forma a definir limites na análise do modelo de previsão.

Tabela 5.1 - Histórico de paragens na fábrica III

	2014	2015	2016	2017
Paragem Geral	12 de março a 28 de abril	-	22 de janeiro a 2 de abril	-
Shut down da unidade	22 de maio, 28 de junho, 12 de setembro, 20 de novembro	2 de abril, 14 de julho, 25 de outubro, 24 de novembro	5 de setembro, 22 de novembro	6 de fevereiro, 20 de março, 11 de abril

5.2.2 Indicador de eficiências

Na determinação dos indicadores de eficiência existiu a necessidade de se estudar o comportamento histórico dos permutadores de calor, a fim de se encontrar os valores críticos que indiquem um funcionamento com baixos níveis de *performance*.

Na identificação dos valores ótimos, médios e dos indicadores de baixo eficiência térmica utilizou-se uma analogia que relaciona o rácio de eficiência térmica com o número de unidades de transferência. A eficiência térmica encontra-se diretamente ligada a estes dois parâmetros e é possível determinar qual a eficiência térmica máxima que determinado permutador de calor pode atingir dentro de uma gama de caudais, respetivas capacidades caloríficas, e temperaturas. O número de unidades transferência aumenta quanto maior for o coeficiente global de transferência de calor, ou a eficiência térmica.

A figura 5.2 representa a relação acima descrita entre o rácio das taxas de capacidade calorífica dos dois caudais de entrada ao permutador de calor e o seu número de unidades de transferência.

Por forma a não comprometer um funcionamento adequado de cada permutador de calor, definiram-se as mesmas percentagens aos valores obtidos de NTU para cada um destes. O valor ótimo é definido como o valor mais elevado de NTU e tem a cotação de 100%. O valor aceitável é o valor em torno do qual se espera que o permutador de calor deva funcionar sob condições adequadas de permuta de calor e tem uma cotação de 80% em relação ao número de unidades de transferência ótimo. O valor obtido para o 1º indicador representa um primeiro aviso de que a eficiência do permutador se encontra baixa, e foi lhe dada a cotação de 60% em relação ao valor de design das NTU , e o 2º indicador refere-se a um valor muito baixo de eficiência para o qual se deve prestar atenção pois indica que o permutador se encontra a funcionar longe dos valores adequados para a transferência ideal de calor no equipamento, e é considerado um valor de 50% em relação ao valor de design das NTU . Os valores de eficiência ótima, aceitável, 1º indicador e 2º indicador, encontram-se na tabela 5.2.




Figura 5.2 - Eficiência térmica em função de NTU e Cr . [20]

Tabela 5.2 - Eficiências ótimas e indicadores de baixa eficiência para cada permutador

Permutadores	Cr médio	NTU design	Valor ótimo	Valor aceitável	1º indicador	2º indicador
HC-E-21	0,66	3,36	86%	81%	74%	69%
HC-E-22	0,86	2,30	75%	68%	60%	55%
HC-E-24	0,69	1,40	64%	57%	49%	44%
HC-E-25	0,27	5,03	99%	96%	92%	88%
HC-E-31	0,33	1,30	65%	60%	51%	45%
HC-E-46	0,50	1,95	77%	70%	61%	56%

O valor ótimo refere-se ao valor ideal do permutador de calor com menor valor de incrustações possível, o valor aceitável refere-se à média dos valores de eficiência térmica após uma intervenção. Estes foram determinados com base nos valores de projeto do permutador.

5.3 Efeito das variáveis na eficiência térmica

Ao longo do tempo de estudo é esperado que a eficiência térmica apresente sinais de decaimento, provocadas principalmente pela iniciação da formação de *fouling* durante a passagem dos fluídos no equipamento.

Na análise da eficiência térmica em permutadores de calor as temperaturas de entrada são as variáveis principais que nos permitem analisar as condições iniciais do permutador de calor, fundamentais para calcular a capacidade máxima em transferência de calor. Como todos os permutadores de calor realizam integração energética a sua eficiência depende das cargas alimentadas à unidade e das condições de operação dos reatores de *hydrocracking*. A análise das eficiências térmicas é feita em comparação com a tendência da *LMTD*, temperaturas de saída e entrada, e caudais de passagem no tubular e corpo.

Os caudais de entrada influenciam a eficiência térmica num permutador de calor, bem como o coeficiente de transferência de calor. Dependendo da composição da corrente e do valor de caudal, são obtidos diferentes valores de *performance*, mesmo que não se verifique a formação de *fouling*. A partir da tabela 5.3 podemos verificar de que modo temperaturas e caudais influenciam a *LMTD*, eficiência térmica e o coeficiente global de transferência de calor. No caso de se verificar um aumento nas variáveis o efeito é oposto àquele que é apresentado na tabela 5.3.

Tabela 5.3 - Variação da *LMTD*, eficiência e *U* com a diminuição das variáveis

Temperatura	<i>LMTD</i>	Eficiência térmica	<i>U</i>
Diminuição da temperatura de entrada do fluido com C_{min}	Aumenta	Aumenta	Aumenta
Diminuição da temperatura de saída do fluido com C_{min}	Aumenta	Diminui	Diminui
Diminuição da temperatura de entrada do fluido com C_{max}	Diminui	Aumenta	Aumenta
Diminuição da temperatura de saída do fluido com C_{max}	Diminui	Não afetada	Aumenta
Diminuição do caudal do fluido com C_{min}	Não afetada	Aumenta	Diminui
Diminuição do caudal do fluido com C_{max}	Não afetada	Diminui	Aumenta

5.3.1 Permutador de calor HC-E-21

As condições de entrada no permutador de calor HC-E-21, são influenciadas principalmente pela qualidade da carga de *LVGO* alimentada ao reator HC-R-01, as condições de operação no reator e a temperatura da carga proveniente das outras unidades presentes na refinaria. Para este permutador a taxa de capacidade calorífica mínima encontra-se na corrente de passagem nos tubos.

A temperatura de entrada no lado do corpo vai aumentando ao longo do tempo como pode ser observado pela figura 5.3 por forma a compensar a perda de atividade do catalisador no reator de *hydrocracking* HC-R-01. Após a paragem de 2016, esta temperatura volta para valores mais baixos, devido à renovação do catalisador. A temperatura de entrada no lado dos tubos por sua vez, mantém-se razoavelmente constante ao longo do tempo já que esta é controlada pelas cargas provenientes da armazenagem, da fábrica 1 e da fábrica 2.

Relacionando os dados da figura 5.3 com os da figura 5.4, verifica-se um afastamento entre as temperaturas de cada extremo do permutador de calor HC-E-21. Embora a temperatura de entrada nos tubos não variar significativamente até ao fim do ano de 2015, a temperatura de saída vai diminuindo o que induz a um efeito de diminuição do calor transferido. Por sua vez a temperatura de saída da corrente efluente ao reator de primeiro estágio apresenta uma tendência para aumentar, fruto da diminuição da capacidade para trocar calor por parte do permutador de calor, podendo mesmo apresentar outro tipo de problemas associados, como deposição de catalisador proveniente do reator, ou deformação mecânica do próprio equipamento. As variações das temperaturas nos extremos do permutador de calor serão as responsáveis pelo aumento ou diminuição da *LMTD*.

Em permutadores de calor contracorrente verifica-se que quanto maior a taxa de *fouling* no permutador maior o valor da *LMTD*, e menor a eficiência térmica. Para além do *fouling* a *LMTD* também varia conforme as variações nas temperaturas à entrada do permutador. Para verificar a ocorrência de fenómenos adversos à *performance* destes equipamentos é necessário determinar primeiro se não houve alteração nas condições de entrada.

A *LMTD* aumenta no caso deste permutador pois a diferença de temperatura entre a corrente que sai dos tubos e a corrente que entra no corpo também aumenta, não se verificando a mesma taxa de crescimento no outro extremo, causa indireta da desativação do catalisador no reator. Este efeito induz a uma diminuição da eficiência térmica como verificado na figura 5.5. Observando a figura 5.4 é possível verificar que a temperatura de saída do corpo é sensivelmente constante até ao fim do ano de 2015, e que as condições à entrada dos tubos pouco se alteram, o que demonstra que o aumento na *LMTD* se deve principalmente às condições presentes nos tubos. Este aumento da *LMTD* aliado ao facto da diminuição do calor trocado devido à diminuição da temperatura na corrente de saída dos tubos, proporciona uma queda no valor do coeficiente global de transferência de calor, como se pode observar pela figura 5.6.

O coeficiente global de transferência de calor foi calculado por dois métodos distintos, o da eficiência *NTU* e o do calor trocado. Pretende-se com esta ilustração validar os cálculos efetuados no modelo de previsão linear anteriormente explicados, em que o coeficiente é calculado com base no método das *NTU*.

No caso deste permutador de calor considera-se que não existe um forte impacto do rácio dos caudais utilizados sobre a eficiência térmica pois a corrente com C_{min} acompanha as variações do C_{max} . Individualmente as correntes de entrada podem influenciar a eficiência térmica devido à sua composição, como o teor em enxofre, que pode acelerar o processo de formação de incrustações e diminuir a eficiência do *cracking*, e a presença de azoto que provoca desativações do catalisador. Caudais baixos, diminuem a velocidade de passagem no interior do permutador de calor aumentando a deposição de partículas indesejadas devido a uma diminuição da turbulência.

Este permutador de calor apresenta variações irregulares na eficiência térmica devido a *shut down*'s na unidade, ou paragens súbitas. Estas paragens forçam a unidade a parar por completo, provocando a passagem de hidrogénio a alta pressão aquando do arranque da mesma, limpando o permutador e aumentando a sua eficiência térmica, por breves períodos de tempo (cerca de 1 mês). Antes da paragem de 2016, tinha sido identificado como hipótese para a degradação da *performance* do permutador que provavelmente se devia a um *fouling* severo no lado dos tubos, devido à não existência de condições para incrustar o corpo do equipamento, e a não ocorrência de deposição de catalisador. Esta suposição não obteve a comprovação pretendida, pois os valores de eficiência térmica acabaram por continuar abaixo dos pretendidos, o que pode ser causado por incrustações não previstas ou pela eventualidade

de falhas mecânicas no equipamento como a deformação de *baffles*, que induzem a uma diminuição da turbulência no equipamento e consequente diminuição da troca calorífica.




Figura 5.3 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-21




Figura 5.4 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-21




Figura 5.5 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-21




Figura 5.6 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-21

5.3.2 Permutador de calor HC-E-22

As condições de entrada no permutador de calor HC-E-22 são principalmente influenciadas pela qualidade da carga de alimentação ao reator HC-R-02 que é proveniente do fundo da coluna de *stripper*, o teor de azoto presente na composição da mesma e as condições de operação do reator.

Tal como no permutador de calor HC-E-21, existe um aumento progressivo da temperatura de entrada do lado do corpo do HC-E-22, que resulta da desativação do catalisador presente no reator de *hydrocracking* de segundo estágio. Pela figura 5.7, pode-se verificar que em meados de junho de 2016 existe uma diminuição da temperatura desta corrente em cerca de 40°C, valores que poderiam ser confundidos como falhas de medição por parte do sensor, mas que na realidade são consequência das desativações sofridas pelo catalisador. Isto deve-se ao elevado teor de azoto presente na carga do reator do segundo estágio, que provoca desativações no catalisador. Este fenómeno ocorre devido ao envenenamento temporário do catalisador, pela adsorção do azoto nas suas partes ácidas, o que provoca a neutralização dos centros ácidos, resultando numa redução da eficiência do *cracking*, e que conduz a uma diminuição da temperatura. Isto demonstra que é necessário otimizar os parâmetros de filtragem de modo a eliminar as componentes de alta frequência do ruído, sem eliminar as frequências características da dinâmica de *fouling*.

Embora não exista variação entre as temperaturas à saída do permutador, o efeito verificado nas temperaturas à entrada, produzem um aumento gradual na *LMTD*, e consequente diminuição da eficiência térmica como observado na figura 5.9. Estes efeitos são consequência indireta da desativação do catalisador ao longo do tempo, e da baixa deposição de partículas neste permutador.

Os caudais de entrada neste permutador apresentam entre si um rácio de taxas de capacidade caloríficas similar ao longo do histórico observado, o que leva a não se verificar uma influência direta destes sobre a eficiência térmica. Os caudais no corpo e tubos são idênticos porque este permutador faz a integração energética das correntes de entrada e saída do reator de 2º estágio, ver anexo II.

A variação do caudal que possui a C_{min} varia de igual forma que a que possui a C_{max} neste permutador de calor, o que leva o coeficiente global de transferência de calor a variar de igual forma que a eficiência térmica como pode ser observado pelas figura 5.9 e figura 5.10

Os indicadores de *performance* deste permutador ficaram sempre acima dos patamares de alarme (1º e 2º indicadores) definidos.




Figura 5.7 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-22




Figura 5.8 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-22




Figura 5.9 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-22




Figura 5.10 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-22

5.3.3 Permutador de calor HC-E-24

As condições de entrada no permutador de calor HC-E-24 são principalmente influenciadas pelas condições de operação nos permutadores de calor HC-E-21 e HC-E-22, e pela coluna de *stripper*, HC-V-02. A taxa de capacidade calorífica mínima neste permutador encontra-se na corrente de passagem no corpo.

A corrente de entrada no corpo deste permutador é proveniente da coluna de *stripper* HC-V-02. Esta coluna separa os produtos mais pesados, direcionados para a coluna de fracionamento, do dióxido de enxofre, a *LPG* (C_3 e C_4) e a nafta leve (C_5 e C_6), que são encaminhados para a secção de produtos leves. A coluna HC-V-02 opera à temperatura que é definida pela coluna de separação a alta pressão e a alta temperatura, HC-V-22, devido à integração existente com o permutador de calor HC-E-25. A válvula que se segue à coluna de *stripper* controla o fluxo de produto por forma a manter o nível pretendido no interior da coluna. A temperatura desta é mantida acima do ponto de orvalho da água para permitir um *stripping* mais suave e proteger os enchimentos presentes na coluna da corrosão. A evolução histórica da temperatura de entrada no corpo do HC-E-24 não sofre grandes alterações mantendo-se relativamente constante ao longo do tempo como verificado pela figura 5.11.

A temperatura de entrada no lado dos tubos sofre as mesmas variações que ocorrem com as temperaturas de saída dos permutadores de calor HC-E-21 e HC-E-22. Esta temperatura é influenciada pela *performance* destes permutadores e pelas condições dos dois reatores de *hydrocracking*.

As temperaturas à saída do permutador mantêm-se relativamente constantes ao longo do tempo, com exceção nos meses antecedentes à paragem de 2016, onde se verificou um pequeno aumento da temperatura de entrada, consequência das mais elevadas temperaturas de reação nos reatores de *hydrocracking*, o que afetou as temperaturas à saída dos tubos como pode ser observado na figura 5.12. Como a corrente que passa no corpo do permutador de calor possui a taxa de capacidade calorífica mínima, a temperatura à saída dos tubos não tem relevância para o cálculo da eficiência térmica.

A variação da *LMTD* para este permutador de calor segue a tendência observada nos permutadores anteriores, aumentando aquando da diminuição da eficiência térmica no histórico em questão, como observado pela figura 5.13.

Neste permutador existe uma particularidade na relação existente entre os caudais de entrada e a influência destes sobre a eficiência térmica e o coeficiente global de transferência de calor. Como se pode observar pela figura 5.11, a temperatura da corrente de entrada que possui a taxa de capacidade calorífica mínima, entrada no corpo, mantém a temperatura constante ao longo do tempo, enquanto que a sua temperatura de saída diminui por um pequeno período após a paragem de 2016. Esta diminuição é consequência da temperatura mais baixa à entrada nos tubos, o que leva a uma menor transferência de calor. Este fenómeno leva a *LMTD*, a eficiência térmica e o coeficiente global de transferência de calor

a diminuir. Os valores de eficiência térmica aumentam devido a um menor rácio entre o C_{min} e o C_{max} , o que leva a se verificar a diferença observada entre a eficiência térmica e o U nas figura 5.13 e na figura 5.14. Uma diminuição na velocidade de passagem, faz baixar o nº de *Reynolds*, e consequentemente a transferência de calor, e o U .




Figura 5.11 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-24




Figura 5.12 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-24




Figura 5.13 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-24




Figura 5.14 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-24

5.3.4 Permutador de calor HC-E-25

As condições de entrada no permutador de calor HC-E-25 são principalmente influenciadas pelas colunas de separação HC-V-22, separadora de alta temperatura e alta pressão, e HC-V-25, separador de baixa temperatura e baixa pressão. A coluna de separação HC-V-25 é indiretamente influenciada pelas temperaturas recebidas por outras duas colunas de separação, HC-V-23, separador de alta temperatura e baixa pressão, e HC-V-24, separador de baixa temperatura e alta pressão, bem como pelo permutador de calor HC-E-32 que realiza troca calorífica com a água de arrefecimento e com o *diesel sponge oil*. A taxa de capacidade calorífica mínima encontra-se na corrente de passagem no corpo, para este permutador.

Ao analisar figura 5.15 verifica-se que a temperatura da corrente de entrada nos tubos deste permutador não sofre variações significativas ao longo do tempo. Esta é a corrente de saída no topo da coluna de separação HC-V-22, que separa o excesso de hidrogénio e outros gases formados nos reatores, dos produtos. A temperatura da corrente de entrada na coluna HC-V-22 deve ser mantida a uma temperatura que se encontre muito próxima dos 243 °C, por forma a que o efluente líquido da coluna enviado para a secção de fracionamento possa ter uma elevada temperatura, para que permita diminuir a área de transferência necessária à troca calorífica no reaquecimento do óleo utilizado para o fracionamento, e para permitir minimizar o calor necessário na fornalha de alimentação à coluna de fracionamento.

Relativamente à temperatura da corrente de entrada no corpo do permutador, esta também se mantém sensivelmente constante ao longo do tempo, com flutuações pouco significativas. Como referido anteriormente, a temperatura desta corrente é proveniente da coluna de separação HC-V-25 que recebe as correntes vindas das colunas HC-V-23 e HC-V-24, sendo estas combinadas e arrefecidas no aero-arrefecedor HC-E-02 até uma temperatura de 60°C antes de entrarem na coluna HC-V-25. Variações nas temperaturas de operação destes equipamentos, e em especial do HC-E-02, são uma possível causa para a verificação das pequenas flutuações observadas na temperatura da corrente de entrada no corpo.

O permutador de calor HC-E-25 tem um sistema de lavagem incorporado, devido à formação de sais inorgânicos como o sulfureto de amónia, e o cloreto de amónia. O sulfureto de amónia raramente precipita às temperaturas de operação do HC-E-25, ao contrário do cloreto de amónia, mas muito pouco deste encontra-se presente na corrente proveniente da coluna HC-V-25 não sendo necessária a elaboração de ciclos programados de lavagem ao permutador.

Tendo em conta que a taxa de capacidade calorífica mínima se encontra na corrente de passagem no corpo, variações na temperatura à saída dos tubos não serão de grande relevância para o cálculo da eficiência térmica. Observando a figura 5.16 verifica-se uma diminuição na temperatura à saída do corpo relativamente à verificada na temperatura à entrada do mesmo, diminuindo a eficiência térmica como observado pela figura 5.17.

No permutador HC-E-25 a tendência observada nos históricos da eficiência térmica e do coeficiente global de transferência de calor é diferente daquele observado nos permutadores de calor anteriormente analisados.

Observando o período imediatamente a seguir à paragem de 2014 verifica-se um elevado valor de eficiência em contraste com os valores calculados para o coeficiente global de transferência de calor observados na figura 5.18. Isto deve-se a uma baixa passagem de caudal, com menor taxa de capacidade calorífica, que diminui o U e aumenta a eficiência. As variações observadas no caudal proveniente da coluna HC-V-25 podem ser indicativas da utilização de caudais de alimentação ao reator com diferentes composições, levando a que exista uma alteração na quantidade de produtos separados em cada coluna de separação.

Após a paragem de 2016 o caudal que passa no corpo volta a diminuir, e imediatamente se verifica uma diminuição do coeficiente global de transferência de calor em contraste com a eficiência térmica.




Figura 5.15 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-25




Figura 5.16 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-25




Figura 5.17 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-25




Figura 5.18 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-25

5.3.5 Permutador de calor HC-E-31

No permutador de calor HC-E-31 as temperaturas das correntes de entrada, são principalmente influenciadas pelas condições de fracionamento da coluna HC-V-03, pelo *diesel stripper* HC-V-06 e pela *performance* do permutador de calor HC-E-29. A variação histórica das temperaturas de entrada encontra-se representada na figura 5.19. A corrente que passa nos tubos possui a menor taxa de capacidade calorífica neste permutador.

Como observado pela figura 5.20, as temperaturas das correntes à entrada do permutador não variam significativamente. A temperatura na corrente do corpo corresponde ao *LVGO*, proveniente do armazenamento dos destilados de vácuo. Algum tipo de variação mais acentuada na tendência desta série de dados poderia dever-se a uma diminuição da *performance* do permutador HC-E-29, que se encontra imediatamente antes do HC-E-31.

A corrente de entrada nos tubos do permutador de calor provém do fundo da coluna de *diesel stripper* HC-V-06, que utiliza vapor de baixa pressão para remover compostos leves do produto. Antes desta passar pela coluna de *stripper*, o *diesel* é separado na coluna de fracionamento HC-V-03 no prato 22. A temperatura da corrente de *diesel* apresenta flutuações ao longo do tempo que podem ser explicadas pelas alterações nas condições de corte, consoante as exigências do mercado. Entre janeiro e agosto de 2017, é verificado uma diminuição significativa da eficiência, acompanhada pela diminuição da *LMTD*. Isto deve-se a uma diminuição da diferença de temperatura entre os extremos do permutador, provocada pela diminuição da corrente de passagem no corpo. Como a taxa de capacidade calorífica mínima se

encontra na corrente de passagem nos tubos, essa diminuição leva a um aumento do C_r e diminuição da eficiência térmica como observado pela figura 5.21.

Como a temperatura dos tubos diminui à entrada e aumenta à saída, cria uma combinação de fatores leva a que se verifiquem diminuições na eficiência, no coeficiente global e na $LMTD$ como verificado na figura 5.21 e na figura 5.22. Embora a $LMTD$ diminua em vez de aumentar, como se tem verificado, é visível o aparecimento de *fouling* no lado dos tubos para este permutador. Do lado do corpo não se verificam fatores que preocupem, pois trata-se de carga limpa, que apenas pode influenciar este permutador em caso de diminuição da *performance* no permutador HC-E-29.




Figura 5.19 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-31




Figura 5.20 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-31




Figura 5.21 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-31




Figura 5.22 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-31

5.3.6 Permutador de calor HC-E-46

As temperaturas à entrada do permutador de calor HC-E-46 são principalmente influenciadas pelas condições de operação da coluna de fracionamento HC-V-03, pela eficiência da fornalha HC-F-03, e pelas *performances* dos permutadores de calor HC-E-23 e HC-E-24, e indiretamente pela *performance* dos permutadores de calor HC-E-21 e HC-E-22. A corrente que passa nos tubos deste permutador, possui a menor taxa de capacidade calorífica.

Como observado pela figura 5.23 as temperaturas à entrada do permutador HC-E-46 apresentam um comportamento relativamente constante ao longo do tempo, excetuando os últimos meses do período em análise onde tanto a temperatura à entrada do corpo como a temperatura à entrada dos tubos aumentaram. A temperatura de entrada no corpo apresentou uma tendência de subida devido à quebra de *performance* verificada no permutador de calor HC-E-24, levando a um aumento da temperatura do caudal que segue para o HC-E-46. A carga à entrada dos tubos é *unconverted oil* proveniente do fundo da coluna de fracionamento, e é expectável que esta não sofra alterações relevantes a nível da temperatura.

Relativamente às temperaturas de saída verifica-se um ligeiro aumento na que sai do tubular, que pode ser explicado pelo aumento do poder calorífico da corrente de *unconverted oil*, por incluir na sua composição uma maior quantidade de *HPNA* (ppm), aromáticos formados no reator HC-R-02, que podem apresentar uma maior capacidade calorífica levando a um aumento da temperatura. Este aumento

de temperatura leva a um aumento da eficiência térmica, como se pode observar pela figura 5.24, nos meses seguintes à paragem de 2016 onde esta aumenta continuamente.

A diminuição do C_r devido à diminuição da corrente no fundo da coluna de fracionamento, também pode ser uma causa que beneficie o aumento da eficiência térmica levando desta forma a haver uma maior variação de temperaturas. Esta causa é visível ao se analisar a figura 5.26 observando-se uma diminuição do coeficiente global de transferência de calor quando a eficiência aumenta, devido à diminuição do caudal que tem a C_{min} , levando a diminuir a velocidade de passagem nesse lado do permutador e consequentemente a diminuir o U .




Figura 5.23 - Histórico da variação das temperaturas das correntes à entrada do permutador HC-E-46




Figura 5.24 - Histórico da variação das temperaturas das correntes à saída do permutador HC-E-46




Figura 5.25 - Variação histórica da eficiência térmica e da LMTD no permutador de calor HC-E-46




Figura 5.26 - Variação histórica do coeficiente global de transferência de calor no permutador de calor HC-E-46

5.4 Comparação do filtro com os dados medidos

Neste capítulo são introduzidos os dados obtidos através dos filtros de ruído e de filtragem utilizados no modelo de previsão. Serão apresentadas as filtrações elaboradas para o permutador de calor HC-E-21 como exemplo de funcionamento.

Os dados foram filtrados utilizando o filtro de mínimos quadrados com um filtro de passa-baixo usando diferentes números de pontos dependendo do espaço temporal pedido para a execução do modelo de previsão, isto é permitir ao filtro passar frequência mais altas no caso de previsões para um espaço temporal mais curto, e passar frequências mais baixas para previsões com um espaço temporal mais longo. Por exemplo caso se pretenda uma previsão para 2 semanas a filtragem utilizada, é uma de mínimos quadrados utilizando 28 pontos da série (2 semanas) de dados (filtro que permite a passagem de altas frequências), como representado na figura 5.27, podendo-se analisar com clareza o decaimento durante esse período. Se a janela de filtragem fosse maior que a janela de previsão existiria o risco de se estar a eliminar componentes de frequência mais elevadas necessárias a uma previsão para um curto espaço temporal. No caso de uma previsão de 6 meses pretende-se que esta seja o mais linearizada possível por forma a evitar a captação de flutuações significativas pelo modelo linear, diminuindo os seus graus de confiança em relação à correlação linear e de determinação entre as variáveis. Caso se utilizasse um filtro que permitisse a passagem de altas frequências para uma previsão de 6 meses poderia se correr o risco de se obter previsões com valores extremamente pessimistas, ou que apresentasse mesmo valores negativos.

Desta forma a filtragem das séries de dados é um passo preponderante para se obter extrapolações que apresentem o maior grau de confiança e menor incerteza possíveis. A figura 5.32 demonstra os 6 filtros utilizados para cada previsão, com as suas diferentes filtrações consoante o espaço temporal pretendido para a extrapolação. Da figura 5.28 à figura 5.31 é ilustrado o comportamento dos outros filtros, calculados dependendo do tempo de previsão utilizado no permutador de calor HC-E-21

HC-E-21




Figura 5.27- filtragem dos dados medidos por mínimos quadrados com 28 pontos




Figura 5.28- filtragem dos dados medidos por mínimos quadrados com 56 pontos




Figura 5.29- filtragem dos dados medidos por mínimos quadrados com 84 pontos




Figura 5.30- filtragem dos dados medidos por mínimos quadrados com 180 pontos




Figura 5.31- filtragem dos dados medidos por mínimos quadrados com 240 pontos




Figura 5.32- filtragem dos dados medidos por mínimos quadrados com 360 pontos

5.5 Validação dos métodos

Para verificar se as técnicas de previsão implementadas no modelo captam as tendências passadas com precisão, realizaram-se validações que analisam as discrepâncias entre os valores filtrados e os valores previstos pelo modelo. Desta forma trataram-se os dados no período pós paragem 2016 por forma a que o último dia de previsão fosse o dia 7 de agosto de 2017, admitindo esta como a data de uma nova paragem. Serão apresentadas neste capítulo as validações correspondentes às previsões de 6 meses, as restantes validações encontram-se no Anexo III.

5.5.1 Modelo Linear

Na análise das validações foram tidas em conta as variâncias e os desvios padrões entre a série de dados real estimada e a série prevista pelo modelo e os intervalos de previsão. Foi definido um valor de desvio padrão máximo de 5% para garantir um ajuste adequado da reta de previsão em relação à série estimada e o intervalo de previsão foi calculado para um nível de significância de 5%.

O desvio padrão pretende verificar os desvios da série de dados prevista em relação aos dados reais, e o intervalo de previsão pretende verificar a incerteza associada à extrapolação analisando se os valores calculados apresentam discrepâncias que não permitam afirmar com certeza que a previsão é de confiança.

Estas validações não significam que o modelo apresente sempre o tipo de comportamento que será demonstrado, podendo os resultados dos métodos de validação serem diferentes consoante as variações verificadas na série de dados estimados, por alterações no processo fabril, ou paragens da unidade. Os dados previstos podem elaborar previsões que mostrem um baixo grau de confiança, devido a uma possível instabilidade verificada na curva das observações de eficiência térmica passadas.

HC-E-21

Os resultados verificados na figura 5.33 demonstram um desvio padrão e uma variância aceitável e dentro dos parâmetros definidos. A variação verificada no tempo final é indicativa de uma recuperação por parte do nível de eficiência após um *shut down* da unidade em março de 2017. Os dados estimados referentes a uma filtragem de 6 meses apresentam associado um atraso que permite visualizar a recuperação apenas algum tempo após esta ocorrer.

O grau de confiança apresentado para esta validação é bom, pois existe uma probabilidade de 95% do valor real da previsão se encontrar num intervalo com $\pm 2\%$ de diferença em relação aos valores extrapolados. Como se trata de uma previsão esta afirmação não tem de ser necessariamente verdadeira, devido à possibilidade da ocorrência de fatores externos que alterem o curso da série. A tabela 5.4 apresenta os resultados obtidos nas validações das previsões para os diferentes intervalos de tempo presentes no modelo.




Figura 5.33 - Validação para a previsão de 6 meses no permutador HC-E-21 após a paragem de 2016

Tabela 5.4- Indicadores estatísticos para as validações no permutador HC-E-21 após a paragem de 2016

Intervalo de tempo da previsão	Variância	Desvio padrão	Intervalo de previsão
2 semanas	0,004%	0,60%	Intervalo de confiança
4 semanas	0,01%	1,10%	Intervalo de confiança
6 semanas	0,004%	0,64%	Intervalo de confiança
3 meses	0,20%	4,44%	Muito baixo grau de confiança
4 meses	0,26%	5,13%	Baixo grau de confiança
6 meses	0,05%	2,34%	Baixo grau de confiança

HC-E-22

No permutador de calor HC-E-22, observa-se uma grande discrepância entre a série de dados estimada e a série com os dados previstos, não existindo uma adaptação clara entre o modelo e o real comportamento da eficiência térmica neste permutador. Isto deve-se a uma recuperação de eficiência que se seguiu após um longo período de descida como pode ser verificado na figura 5.9. Isto levou o modelo a determinar um decaimento progressivo da série, quando na realidade ela manteve um comportamento constante como observado na figura 5.34. O desvio padrão entre a série de dados previstos e a série real é de 7.9%, fora do limite inicialmente definido de 5%.

Para demonstrar resultados que se aproximem dos esperados, elaborou-se também uma validação para uma previsão de 6 meses após a paragem de 2014 até 22 de janeiro de 2016, aquando do início da paragem realizada nesse mesmo ano, por forma a verificar se o modelo se ajustava aos resultados pretendidos devido a não existirem variações significativas na eficiência levados a cabo por fatores externos durante a regressão e a extrapolação. Pela figura 5.35 é possível perceber que o modelo prevê com uma reduzida incerteza caso não se verifiquem alterações na eficiência térmica no futuro. O desvio padrão entre a série real estimada (filtrada) e os dados previstos é de 0.44% dentro do valor definido inicialmente de 5%. Na tabela 5.5 encontram-se os resultados relativos às validações das diferentes previsões presentes no modelo.




Figura 5.34 - Validação para a previsão de 6 meses no permutador HC-E-22 após a paragem de 2016




Figura 5.35 - Validação para a previsão de 6 meses no permutador HC-E-22 após a paragem de 2014

Tabela 5.5 - Indicadores estatísticos para as validações no permutador HC-E-22 após a paragem de 2016

Intervalo de tempo da previsão	Variância	Desvio padrão	Intervalo de previsão
2 semanas	0,002%	0,43%	Intervalo de confiança
4 semanas	0,001%	0,25%	Intervalo de confiança
6 semanas	0,01%	0,78%	Intervalo de confiança
3 meses	0,002%	0,41%	Intervalo de confiança
4 meses	0,01%	0,83%	Intervalo de confiança
6 meses	0,63%	7,92%	Muito baixo grau de confiança

HC-E-24

A validação do permutador de calor HC-E-24 apresenta resultados que se encontram fora dos limites propostos inicialmente. Como já referido anteriormente estes resultados não implicam que este comportamento seja verificado em todos os casos, mas a sua natureza é eficaz quando são analisados comportamentos que se assemelham com série lineares. Não obstante devido à filtragem de mínimos quadrados elaborada aos valores observados, a previsão pode ser extrapolada a partir de uma série que apresente o maior grau de linearidade possível. O comportamento verificado pelo modelo do permutador HC-E-24 deve-se à descida de eficiência registada no intervalo de tempo utilizado pela regressão, o que indica uma continuidade no decaimento da eficiência. O *shut down* da unidade em março de 2017 levou a uma subida da eficiência deste permutador, que dispôs os dados reais com a tendência demonstrada pela figura 5.36.




Figura 5.36 - Validação para a previsão de 6 meses no permutador HC-E-24 após a paragem de 2016

Tabela 5.6 - Indicadores estatísticos para as validações no permutador HC-E-24 após a paragem de 2016

Intervalo de tempo da previsão	Variância	Desvio padrão	Intervalo de previsão
2 semanas	0,0001%	0,11%	Intervalo de confiança
4 semanas	0,01%	0,81%	Intervalo de confiança
6 semanas	0,0004%	0,20%	Intervalo de confiança
3 meses	0,04%	2,06%	Intervalo de confiança
4 meses	0,01%	1,09%	Baixo grau de confiança
6 meses	0,27%	5,19%	Muito baixo grau de confiança

HC-E-25

A relação entre a série de dados estimados e previstos neste permutador de calor apresenta um breve desvio que se deve a um histórico de eficiência térmica com uma tendência constante durante o tempo de validação, após este ter apresentado uma ligeira diminuição durante um longo período de tempo, que levou o modelo a verificar a discrepância ilustrada na

figura 5.37. A partir do meio de junho de 2017 e até à data final de validação os dados medidos desceram para os valores previstos pelo modelo, devido a problemas associados com o lado do corpo neste permutador de calor, que vem baixando a temperatura de saída ao mesmo decaimento da eficiência térmica. O desvio padrão calculado para esta validação encontra-se dentro dos parâmetros inicialmente definidos, bem como o intervalo de previsão como pode ser verificado pela tabela 5.7.




Figura 5.37 - Validação para a previsão de 6 meses no permutador HC-E-25 após a paragem de 2016

Tabela 5.7 - Indicadores estatísticos para as validações no permutador HC-E-25 após a paragem de 2016

Intervalo de tempo da previsão	Variância	Desvio padrão	Intervalo de previsão
2 semanas	0,01%	0,87%	Intervalo de confiança
4 semanas	0,001%	0,25%	Intervalo de confiança
6 semanas	0,003%	0,51%	Intervalo de confiança
3 meses	0,01%	1,05%	Intervalo de confiança
4 meses	0,002%	0,41%	Intervalo de confiança
6 meses	0,01%	0,87%	Intervalo de confiança

HC-E-31

Neste permutador de calor verifica-se uma elevada discrepância entre os dados filtrados e os dados previstos, obtendo-se um desvio padrão ligeiramente superior àquele inicialmente definido, e com um intervalo de previsão que apresenta um grau de confiança muito baixo. Este acontecimento deve-se à tendência positiva observada na série de dados deste permutador, que levou ao algoritmo de substituição de declive a alterar o declive positivo por um negativo, baixando o grau de confiança da previsão. A série de dados filtrada também sofreu uma alteração súbita, verificando-se uma descida inesperada da eficiência que também influenciou negativamente esta previsão. A validação pode ser observada na figura 5.38, e os resultados na tabela 5.8.




Figura 5.38 - Validação para a previsão de 6 meses no permutador HC-E-31 após a paragem de 2016

Tabela 5.8 - Indicadores estatísticos para as validações no permutador HC-E-31 após a paragem de 2016

Intervalo de tempo da previsão	Variância	Desvio padrão	Intervalo de previsão
2 semanas	0,77%	8,75%	Muito baixo grau de confiança
4 semanas	1,90%	13,80%	Muito baixo grau de confiança
6 semanas	1,15%	10,71%	Baixo grau de confiança
3 meses	0,14%	3,68%	Muito baixo grau de confiança
4 meses	0,06%	2,36%	Baixo grau de confiança
6 meses	0,26%	5,09%	Muito baixo grau de confiança

HC-E-46

O desvio padrão calculado para o permutador de calor HC-E-46 encontra-se dentro dos parâmetros inicialmente definidos, embora se verifique tendências contrárias entre a série de dados estimada e a série de dados prevista. Este efeito deve-se ao comportamento verificado desde a paragem de 2016 onde existe um aumento do caudal de passagem no corpo que leva a um aumento gradual da eficiência. A previsão apresenta uma tendência negativa devido ao algoritmo presente no modelo, que identifica todas as descidas de eficiência verificadas nas janelas de regressão.




Figura 5.39 - Validação para a previsão de 6 meses no permutador HC-E-46 após a paragem de 2016

Tabela 5.9 - Indicadores estatísticos para as validações no permutador HC-E-46 após a paragem de 2016

Intervalo de tempo da previsão	Variância	Desvio padrão	Intervalo de previsão
2 semanas	0,01%	1,11%	Intervalo de confiança
4 semanas	0,01%	0,99%	Intervalo de confiança
6 semanas	0,01%	1,18%	Intervalo de confiança
3 meses	0,05%	2,33%	Baixo grau de confiança
4 meses	0,02%	1,28%	Intervalo de confiança
6 meses	0,02%	1,55%	Muito baixo grau de confiança

5.5.2 Rede Neuronal

Para a rede neuronal as validações são realizadas como parte do intrínseca do modelo, e pretendem mostrar se o ajuste elaborado para a previsão apresenta o mínimo erro possível entre os valores previstos e os valores reais, antes de se iniciar a fase de teste.

As validações foram realizadas entre janeiro e julho de 2017, e foram elaboradas para redes neuronais com diferentes arquiteturas. Foram realizadas experiências para redes que utilizassem 6, 7, 9, 12 e 15 neurónios, por forma a selecionar a que apresentasse o menor valor de erro médio quadrático e o menor valor de erro médio relativo.

Os comportamentos verificados na curva de previsão por parte da rede neuronal onde se verificam fracas aproximações entre as duas séries, devem-se à influência verificada pelos padrões mais antigos de eficiência e aos valores de *input* introduzidos, que induziram a rede a prever decréscimos menos acentuados.

Da figura 5.40, à figura 5.44 ilustram os gráficos de validação obtidos para as redes neuronais com as diferentes arquiteturas utilizadas, sendo possível observar os erros quadráticos médio e erros relativos de cada rede a partir da tabela 5.10. A partir da mesma determinou-se que a rede neuronal que é constituída por uma arquitetura com 9 neurónios é a que apresenta os melhores resultados, tendo sido a utilizada para os testes de previsão.




Figura 5.40 - Validação da rede neuronal com 6 neurónios para o permutador HC-E-21




Figura 5.41 - Validação da rede neuronal com 7 neurónios para o permutador HC-E-21




Figura 5.42 - Validação da rede neuronal com 9 neurónios para o permutador HC-E-21




Figura 5.43 - Validação da rede neuronal com 12 neurónios para o permutador HC-E-21




Figura 5.44 - Validação da rede neuronal com 15 neurónios para o permutador HC-E-21

Tabela 5.10 - Resultados obtidos na fase de treino e validação para a rede neuronal

Nº de neurónios camada escondida	Nº de treinos	Erro quadrático médio (treino 1)	Erro quadrático médio (treino 2)	Erro quadrático médio (treino 3)	Erro quadrático médio (total)	Erro quadrático médio validação	Erro relativo médio validação
6	3	1,33%	2,22%	3,15%	6,70%	12,64%	4,63%
7	3	1,76%	3,07%	2,04%	6,88%	9,85%	4,62%
9	3	0,78%	2,88%	3,08%	6,75%	9,36%	3,85%
12	3	0,75%	2,32%	2,70%	5,77%	10,05%	4,01%
15	3	1,56%	6,33%	3,44%	11,32%	12,89%	4,80%

5.6 Teste dos modelos de previsão

Após a determinação das propriedades dos fluído, da implementação dos modelos, da análise das variáveis que afetam a eficiência térmica e da validação dos métodos, procedeu-se ao teste dos mesmos por forma a verificar quais os resultados que estes devolvem nas próximas semanas e meses. Este foi iniciado a 7 de agosto de 2017, com o principal objetivo de determinar qual seria a eficiência térmica de cada permutador nos próximos 6 meses, tendo-se também previsto as mesmas para 2 semanas, 4 semanas, 6 semanas, 3 meses e 4 meses. Todas estas previsões permitem extrapolar o comportamento de cada permutador ao longo dos 6 meses, consoante o histórico destes nos últimos meses ou mesmo anos. Dependendo do intervalo de tempo utilizado e se existe a estimação dos dados de paragens, a previsão adaptará os dados à filtragem e consequentemente à estimação da reta utilizada para a extrapolação dos dados.

Na utilização da rede neuronal o princípio é idêntico ao do modelo linear, no processo de tratamento de dados, mas diferente na execução do modelo. Esta utiliza uma maior gama de dados e, portanto, a sua memória tem em conta dados mais antigos para além de atribuir a mesma relevância aos dados das paragens e aos dados de funcionamento do permutador de calor, prevendo os padrões adquiridos ao longo da fase de treino. Esta é uma das desvantagens da utilização deste modelo, não deixando de ser um forte método de previsão, superior ao modelo de previsão linear.

5.6.1 Modelo Linear

Por forma a se determinar a confiança dos modelos de previsão executados foram definidos diferentes indicadores que ajudam na interpretação dos dados. Para essa análise foi utilizado o intervalo de previsão, qual o declive utilizado na extrapolação e um teste de hipótese que permita verificar a linearidade do modelo.

Na atribuição de um grau de confiança aos intervalos de previsão foram definidos limites por forma a restringir a incerteza sobre a variação dos valores extrapolados. Entre 0% e $\pm 1\%$ o intervalo de previsão tem um bom grau de confiança, entre $\pm 1\%$ e $\pm 2\%$ o intervalo de previsão tem um baixo grau de confiança, entre $\pm 2\%$ e $\pm 3\%$, ou valores maiores, o intervalo de previsão tem um grau de confiança muito baixo.

O teste de hipótese tem por base analisar o parâmetro declive, por forma a não se verificar a hipótese nula, ou seja, a não existência de linearidade entre as variáveis dependente e independente resultando em um declive que se aproxime de 0.

O indicador de confiança em relação ao declive indica se o declive calculado na regressão é negativo ou positivo. Caso o declive seja positivo ele será substituído pela média dos decaimentos observados nas janelas de regressão. Cada tendência obtida através deste modelo é influenciada pelos acontecimentos passados dependendo dos intervalos de pontos utilizados na regressão linear, o que induz a diferentes pontos iniciais para cada reta de previsão. As retas que apresentem baixos graus de confiança em relação aos declives, terão uma maior probabilidade de iniciar a previsão em valores mais elevados do que aqueles esperados no futuro, devido ao declive inicialmente calculado ser positivo, caso o declive utilizado na reta de regressão for negativo, o grau de confiança apresentado será bom, e os valores iniciais das retas de previsão iniciarão em valores mais baixos.

HC-E-21

Observando a figura 5.45, identifica-se as diferentes previsões obtidas com a aplicação de diferentes intervalos de tempo. Dependendo do histórico identificado por cada uma das regressões estas realizarão previsões de acordo com os pontos utilizados. Uma previsão de 2 semanas utilizará dados referentes a 2 semanas (28 observações), uma previsão de 4 semanas utilizará dados referentes a 4 semanas (56 observações) e assim sucessivamente. Pretende-se com esta técnica evitar prolongar as extrapolações que tenham intervalos superiores aos do tempo de observação, o que diminuiria a confiança da extrapolação.




Figura 5.45 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-21

A previsão de 3 meses apresenta o maior decaimento de eficiência, determinando que a 3 de novembro de 2017 a eficiência deste permutador será de 56%. Em fevereiro de 2018 o modelo prevê que o valor da eficiência térmica seja de 59,7%.

As inferências estatísticas, declives utilizados e indicadores de eficiência encontram-se representados na tabela 5.11.

Os resultados obtidos para as previsões que apresentem um grau de confiança baixo para o parâmetro de declive, indicam que em termos de uma extrapolação ideal os valores obtidos encontrar-se-iam mais elevados do que aqueles extrapolados pelo modelo. A implementação do algoritmo de substituição dos declives positivos corrige essas tendências.

Os indicadores de eficiência encontram-se todos à data de início da previsão, devido ao permutador de calor HC-E-21 encontrar-se abaixo dos seus valores ideais antes de se iniciar a sua caracterização futura.

Tabela 5.11 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-21

	Desvio padrão da regressão	R	R²	Declive utilizado	Grau de confiança declive	Grau de confiança relação linear	1º indicador	2º indicador
2 semanas	0,38%	16,5%	2,7%	-4,30E-4	Grau de confiança baixo	Hipótese nula verificada	07-08-2017	07-08-2017
4 semanas	0,14%	37,8%	14,3%	-6,96E-5	Grau de confiança bom	boa relação linear	07-08-2017	07-08-2017
6 semanas	0,24%	91,2%	83,2%	-4,42E-4	Grau de confiança bom	boa relação linear	07-08-2017	07-08-2017
3 meses	0,24%	96,4%	92,9%	-4,42E-4	Grau de confiança bom	boa relação linear	07-08-2017	07-08-2017
4 meses	0,43%	10,6%	1,1%	-5,90E-4	Grau de confiança baixo	boa relação linear	07-08-2017	07-08-2017
6 meses	0,65%	39,7%	15,8%	-1,10E-4	Grau de confiança baixo	boa relação linear	07-08-2017	07-08-2017

HC-E-22

Analisando o histórico da eficiência térmica para o permutador de calor HC-E-22 presente na figura 5.9, verifica-se que nas diferentes previsões realizadas os valores previstos não se distanciam de forma significativa uns dos outros. Isto é explicado por não existir um decaimento significativo ao longo do histórico utilizado pelo modelo. Os resultados das diferentes previsões para o permutador HC-E-22 encontram-se ilustrados na figura 5.46.

A partir da tabela 5.12 verifica-se as inferências estatísticas às retas de regressão e às extrapolações. Nas previsões de 2, 4 e 6 semanas, e na previsão de 3 meses os graus de confiança dos declives são baixos devido à série de dados para o mesmo intervalo de tempo apresentar uma tendência positiva. A previsão de 2 semanas apresenta um comportamento com um grau de confiança muito baixo, pois verifica-se a hipótese nula que nos indica uma elevada falta de linearidade nessa regressão. A previsão de 3 meses apresenta um baixo grau de confiança de correlação linear entre a variável tempo, e a variável eficiência térmica.

As pequenas variações identificadas na previsão da eficiência deste permutador devem-se à manutenção de um comportamento relativamente constante com pequenos decaimentos ao longo do tempo.

Os indicadores de eficiência indicam que estes se encontram fora do intervalo de previsão indicando que os valores de baixa eficiência não são atingidos durante a análise de previsão elaborada.




Figura 5.46 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-22

Tabela 5.12 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-22

	Desvio padrão da regressão	R	R ²	Declive utilizado	Grau confiança declive	Grau confiança relação linear	1º indicador	2º indicador
2 semanas	0,03%	27,5%	7,6%	-1,29E-5	Grau de confiança baixo	Hipótese nula verificada	Fora do intervalo de previsão	Fora do intervalo de previsão
4 semanas	0,05%	65,4%	42,8%	-1,09E-4	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 semanas	0,08%	87,9%	77,3%	-1,25E-4	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
3 meses	0,24%	16,8%	2,8%	-1,14E-4	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 meses	0,26%	88,1%	77,6%	-1,41E-4	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 meses	0,42%	29,2%	8,5%	-2,44E-5	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão

HC-E-24

O permutador de calor HC-E-24 Obteve previsões que não verificam decaimentos significativos ao longo do tempo, para qualquer um dos períodos de tempo utilizados como se pode observar pela figura 5.47. Este efeito deve-se à estabilização da eficiência térmica ao longo dos últimos 6 meses que pouco decaiu, e que até verificou alguns picos de crescimento.

Devido às recentes tendências de crescimento verificadas no histórico da eficiência, as previsões apresentam baixos graus de confiança de declive, excetuando a previsão de 6 meses que considera um período mais extenso onde realmente se verificou uma tendência de decaimento na eficiência deste permutador.

A partir da tabela 5.13 verificamos que as retas de regressão calculadas para a extrapolação ajustam satisfatoriamente as séries de dados observadas, e que os valores de baixa eficiência não são atingidos ao longo da análise a este permutador de calor.




Figura 5.47 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-24

Tabela 5.13 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-24

	Desvio padrão da regressão	R	R ²	Declive utilizado	Grau confiança declive	Grau confiança relação linear	1º indicador	2º indicador
2 semanas	0,08%	59,7%	35,59%	-5,95E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 semanas	0,09%	88,8%	78,9%	-7,15E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 semanas	0,11%	80,5%	64,8%	-4,62E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
3 meses	0,00%	89,9%	80,8%	-1,62E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 meses	0,00%	85,9%	73,8%	-5,93E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 meses	0,16%	53,2%	28,3%	-1,96E-5	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão

HC-E-25

As previsões obtidas para o permutador de calor HC-E-25 apresentam diferentes tendências e resultados de previsão com uma certa discrepância como observado na figura 5.48, devido à súbita variação de eficiência verificada nos últimos 4 meses do seu funcionamento. Esta queda na eficiência levou a que as previsões apresentassem um carácter mais pessimista, que não é evidenciado na previsão de 6 meses, onde a eficiência decaía a uma taxa mais baixa e razoavelmente constante. Pela tabela 5.14 verifica-se que a uma adaptação satisfatória entre a reta de regressão e os dados observados, e com bons graus de confiança, excetuando a previsão de 6 meses onde a correlação linear entre a variável tempo, e a variável de eficiência é mais baixa, e a previsão de 2 semanas que apresenta um baixo grau de confiança para o declive calculado.

Relativamente à identificação de uma baixa eficiência por parte do modelo, este determina o dia 10 de setembro de 2017 como o início do período em que o permutador apresentará um declínio na *performance*, isto apenas para uma previsão de 6 semanas. A diferença verificada entre esta previsão e as outras previsões deve-se à previsão de 6 semanas captar um grande decaimento, e extrapolar a regressão durante mais tempo que o verificado na previsão de 4 semanas.




Figura 5.48 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-25

Tabela 5.14 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-25

	Desvio padrão da regressão	R	R ²	Declive utilizado	Grau confiança declive	Grau confiança relação linear	1º indicador	2º indicador
2 semanas	0,16%	58,8%	34,6%	-3,72E-4	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 semanas	0,13%	90,7%	82,3%	-3,36E-4	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 semanas	0,08%	99,1%	98,2%	-4,57E-4	Grau de confiança bom	boa relação linear	10-09-2017	Fora do intervalo de previsão
3 meses	0,17%	96,5%	93,1%	-2,35E-4	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 meses	0,23%	91,9%	84,5%	-1,55E-4	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 meses	0,29%	43,4%	18,8%	-2,68E-5	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão

HC-E-31

No permutador de calor HC-E-31 as previsões obtidas através do modelo utilizado apresentam diferentes tendências devido às várias variações verificadas no histórico da eficiência térmica, e à falta de linearidade observada em certos períodos de tempo como observado na figura 5.49. Devido a estas

irregularidades existem algumas previsões que apresentam baixos graus de confiança, e a previsão de 4 meses é mesmo descartada por se verificar a hipótese nula aquando da elaboração do teste t .

As previsões de 2 semanas, 4 semanas e 3 meses apresentam um baixo grau de confiança em relação ao declive resultado dos altos e baixos encontrados no histórico da eficiência onde a reta de regressão é traçada. Devido a estes efeitos verifica-se também uma oscilação aquando da determinação dos indicadores de eficiência por parte do modelo, que variam conforme os graus de confiança dos declives. No caso deste grau de confiança ser baixo é expectável a observação de um início de previsão em valores mais altos o que leva a que os indicadores sejam atingidos mais tarde do que se o grau de confiança obtido para o declive fosse elevado.

Relativamente à correlação linear entre as variáveis tempo e eficiência térmica verificam-se valores satisfatórios, excetuando a previsão já descartada inicialmente.




Figura 5.49 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-31

Tabela 5.15 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-31

	Desvio padrão da regressão	R	R ²	Declive utilizado	Grau confiança declive	Grau confiança relação linear	1º indicador	2º indicador
2 semanas	0,51%	89,5%	80,1%	-4,27E-3	Grau de confiança baixo	boa relação linear	07/08/2017	14-08-2017
4 semanas	2,85%	65,9%	43,4%	-3,03E-3	Grau de confiança bom	boa relação linear	07/08/2017	23-08-2017
6 semanas	1,47%	88,7%	78,7%	-2,71E-4	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
3 meses	1.83%	82,5%	68,1%	-6,46E-4	Grau de confiança baixo	boa relação linear	18-08-2017	03-10-2017
4 meses	2.09%	0,1%	0.00%	-8,25E-7	Grau de confiança bom	Hipótese nula verificada	07/08/2017	Fora do intervalo de previsão
6 meses	1,35%	76,3%	58,2%	-3,05E-4	Grau de confiança bom	boa relação linear	07/08/2017	19-09-2017

HC-E-46

O histórico de eficiência térmica para o permutador de calor HC-E-46 apresenta irregularidades entre junho e agosto de 2017, o que levou a se verificarem previsões diferentes para os diferentes intervalos de tempo em análise. A previsão de 4 semanas é representada na figura 5.50, mas é descartada de futuras análises devido a se verificar a hipótese nula na elaboração do teste *t* ao parâmetro declive.

A partir da tabela 5.16 podemos verificar a existência de baixos graus de confiança do declive para as previsões de, 6 semanas, 4 meses e 6 meses, devido a estas originalmente possuírem declives positivos. Estes declives positivos verificam-se para a maior parte dos intervalos de previsão devido ao histórico da eficiência térmica apresentar uma tendência ascendente entre setembro de 2016 e abril de 2017, excetuando a previsão de 3 meses onde a eficiência decai no mesmo intervalo de tempo da previsão.

O modelo para este permutador não define uma data onde exista o atingimento de uma eficiência térmica baixa, sendo esse valor inferior aos verificados ao longo do seu histórico.




Figura 5.50 - Resultados das previsões obtidas pelo modelo linear no permutador HC-E-46

Tabela 5.16 - Resultados das inferências estatísticas e indicadores de eficiência no permutador HC-E-46

	Desvio padrão da regressão	R	R ²	Declive utilizado	Grau confiança declive	Grau confiança relação linear	1º indicador	2º indicador
2 semanas	0,18%	94,6%	89,5%	-1,23E-3	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 semanas	0,34%	11,5%	1,3%	-1,29E-4	Grau de confiança baixo	Hipótese nula verificada	Fora do intervalo de previsão	Fora do intervalo de previsão
6 semanas	0,20%	84,1%	70,7%	-1,86E-4	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
3 meses	0,25%	34,3%	11,8%	-3,51E-5	Grau de confiança bom	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
4 meses	0,27%	65,8%	43,3%	-4,55E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão
6 meses	0,20%	61,4%	37,7%	-1,11E-5	Grau de confiança baixo	boa relação linear	Fora do intervalo de previsão	Fora do intervalo de previsão

5.6.2 Rede Neuronal

A rede neuronal apresenta os mesmos padrões que aqueles observados no modelo linear para o permutador de calor HC-E-21. A diferença deve-se ao algoritmo de alteração de declive calculado no modelo linear que evita que sejam elaboradas extrapolações com tendências positivas, evitando que se

verifique os comportamentos de recuperação de eficiência apresentados pela rede neuronal como ilustrado na figura 5.51.

A rede neuronal pró-alimentada prevê com a memória que adquiriu na fase de treino seguindo os vetores de input, que incluem 3 ciclos de temporais de 6 meses por forma a prever os 6 meses seguintes com base nos comportamentos observados. Devido às recuperações de eficiência evidenciadas aquando dos *shut down's* na fábrica, a rede neuronal não descartou esses comportamentos, e projetou um forte decaimento até 17 de setembro de 2017 seguido de uma recuperação até valores mais elevados do que os inicialmente verificados na previsão. Isto deve-se ao facto de a rede neuronal prever um fator externo que provocará um aumento da eficiência, como a possibilidade da ocorrência de um novo *shut down* na unidade.

Não é possível prever a ocorrência de um novo *shut down* na unidade, e a rede neuronal apenas apresenta este comportamento devido a estas acontecerem na sua maioria das vezes quando a eficiência térmica do permutador de calor HC-E-21 se encontra baixa, levando o modelo a assumir uma melhora da eficiência sempre que esta desça para valores muito baixos. Isto acontece devido aos padrões observados nos neurônios de input apresentarem decaimentos ao longo do tempo.




Figura 5.51 -Resultados da previsão obtida pela rede neuronal no permutador HC-E-21

6 Conclusões

As análises elaboradas no presente estudo inserem-se na necessidade de monitorização e identificação de problemas associados aos ciclos de funcionamento dos permutadores e calor presentes na unidade de *hydrocracking*. A capacidade de prever a *performance* destes permutadores com meses de antecedência proporciona uma vantagem na preparação de uma calendarização para intervenções futuras em cada um destes equipamentos, e em perceber tendências fora do comum indicativas da existência de causas especiais que podem estar a afetar a dinâmica da unidade.

As técnicas de previsão foram elaboradas com a utilização do programador do *Microsoft Excel* o *Visual Basic for Applications*, pois a partir deste é possível aceder diretamente à base de dados da refinaria tornando o modelo de previsão automático e com maior facilidade de utilização por parte do usuário.

Para a avaliação da *performance* nos permutadores de calor foi escolhido como técnica de deteção a eficiência térmica por esta poder ser determinada apenas com a utilização das variáveis temperatura. A incorporação do caudal na função de determinação da eficiência serve para a seleccionar o caudal que possui a taxa de capacidade calorífica mínima, necessária à seleção do ΔT utilizado na equação da eficiência térmica. Os caudais são determinados em m^3 a partir da base de dados e a sua conversão teve em conta os perfis de temperatura em função da fração de vapor disponibilizadas pelos dados de design de cada equipamento. Este método foi utilizado por forma a se obter as variações de c_p que permitam identificar, mesmo com um considerável grau de incerteza associado, os valores de C_{min} e C_{max} indispensáveis à determinação do coeficiente global de transferência de calor pelo método do *NTU* e para o cálculo da eficiência térmica.

A nível dos fatores que influencia a eficiência térmica, estes podem ser divididos entre causas diretas e indiretas. Causas diretas são consideradas as variações de caudal, especialmente no caso de diminuição da quantidade de caudal que passa no lado do tubular, que leva a uma diminuição da velocidade de passagem aumentando a deposição de partículas. Outra das causas diretas observadas deve-se à composição dos caudais, que apresentam compostos carbónicos com mais ou menos ligações de hidrogénio que levam a uma maior facilidade na formação de coque, ou o teor em enxofre que permite a formação de um *fouling* de partículas. Ainda relacionado com as causas diretas, as eventuais despressurizações que possam ocorrer aquando de um *shut down* da unidade, podem conduzir a problemas mecânicos como a deformação dos *baffles* que pode conduzir a uma diminuição da turbulência no interior do permutador, influenciando negativamente a transferência de calor.

A nível das causas indiretas considera-se que são os equipamentos que se encontram a montante ou a jusante dos permutadores de calor que exercem maior influência. No caso do permutador de calor HC-E-21 o reator de 1º estágio de *hydrocracking* tem uma forte influência sobre a temperatura da corrente

de entrada no lado do corpo, efeito devido à desativação do catalisador ao longo do tempo. Relativamente ao permutador HC-E-22 é verificada a mesma influência sobre a corrente de entrada no corpo. Por alguns breves períodos de tempo estas desativações podem ser mesmo potenciadas pela presença de azoto na composição da corrente de alimentação ao reator de 2º estágio de *hydrocracking*. No caso do permutador de calor HC-E-25 a formação de amónia nos reatores de *hydrocracking*, que reage com os cloretos presentes na corrente de alimentação, leva à formação de cloreto de amónia que pode levar à corrosão e entupimento deste permutador de calor. No caso do permutador HC-E-46 a formação de aromáticos, *HPNA*, no reator de 2º estágio, sujeitos a algumas temperaturas de operação do HC-E-46 podem sofrer condensação, levando a estes se depositarem na parede do corpo do permutador de calor.

Foi escolhido o modelo de regressão linear simples, não só por ser mais fácil de implementar em *VBA*, e por isso exigir menos recursos computacionais, como sobretudo por ser robusto e captar as tendências pretendidas quando a eficiência do permutador de calor não apresenta flutuações significativas que prejudiquem a estimação dos parâmetros da regressão linear. A partir dos modelos lineares as extrapolações dos mesmos ajustam-se bastante bem no caso de não se verificarem variações súbitas na eficiência devidas às alterações verificadas no processo fabril. Para a verificação da adequação de cada modelo linear implementado foram determinados graus de confiança que permitem determinar se uma regressão se encontra ajustada aos dados obtidos, e verificar qual a incerteza existente nos dados de previsão, através da elaboração de intervalos de previsão. Verificou-se que a baixa linearidade entre as variáveis tempo e eficiência térmica se encontra principalmente relacionada com as alterações na quantidade de caudal de passagem nos permutadores que leve a uma variação do C_r . As estimativas efetuadas apenas com as temperaturas não têm no modelo, o efeito das variações de caudal sobre a eficiência.

A rede neuronal é uma ferramenta bem mais poderosa no que toca a memorizar os padrões das séries de dados observadas. Esta considera que os padrões do passado se repetem no futuro, no entanto não tem em consideração que os ciclos de funcionamento da fábrica não são os mesmos, nem a periodicidade e composição dos *blendings* seguem um padrão cíclico repetível no tempo, nem as cargas à unidade de *hydrocracking*, que têm muita influência no desempenho dos reatores e consequências no tipo de *fouling* e na eficiência dos permutadores. A utilização de ciclos temporais de 6 meses como inputs, permite à rede neuronal captar as variações existentes entre cada ciclo como se estas se tratassem de uma série contínua, e prever com base nos padrões observados. Embora versátil e muito robusta a rede neuronal implementa em *Microsoft Excel* não permite diagnosticar variações súbitas na eficiência da mesma forma que podemos realizar com um modelo linear. Desta forma apenas foi utilizada a rede neuronal no permutador HC-E-21 devido a este ser o que apresentava um histórico com maiores irregularidades por forma a verificar se as previsões obtidas seriam mais coerentes do que aquelas obtidas com o modelo linear.

Após a determinação dos modelos e análise dos seus resultados foram verificados quais os indicadores devolvidos pelo modelo. O método utilizado para a identificação dos valores baixos de eficiência para cada permutador baseou-se nos valores de coeficiente global de transferência de calor e de *NTU* de design, e em percentagens ótimas desses parâmetros com base na *performance* do permutador HC-E-21. A técnica pretendida para este tipo de análise deveria ter-se baseado sobre uma avaliação económica para os permutadores que elaboram permutas caloríficas reacionais onde se mediria qual a eficiência ideal segundo o maior ou menor consumo de gás nas fornalhas.

7 Trabalho futuro

Após a realização desta dissertação, surgem propostas de melhoria ao trabalho realizado, na implementação de técnicas para a previsão da *performance* em permutadores de calor.

A utilização de um programador que incorpore mais bibliotecas, permitiria elaborar técnicas de previsão mais robustas. Seria desta forma possível utilizar modelos que apresentem resultados mais precisos, para maiores períodos de tempo gerando menores incertezas, como os filtros de *Kalman* ou o aprofundamento do estudo das redes neurais.

Dentro do contexto do parágrafo anterior, é recomendado que o cálculo da *performance* seja elaborado com a normalização dos caudais. Isto permitiria identificar mais concretamente a influência do *fouling*, evitando as flutuações observadas no histórico de eficiência térmica, devidas às variações dos caudais.

Bibliografia

- [1] IPIECA, “Saving Energy in the Oil and Gas Industry,” *Int. Pet. Ind. Environ. Conserv. Assoc.*, 2013.
- [2] L. G. S. Bungener, “Energy Efficiency and Integration in the Refining and Petrochemical Industries,” 2016.
- [3] U.S. Energy Information Administration, *International Energy Outlook 2016*, vol. 0484(2016), no. May 2016. 2016.
- [4] L. G. S. Bungener, “Energy Efficiency and Integration in the Refining and Petrochemical Industries,” Jan. 2016.
- [5] “Fundamentos de refinação - Galp.” [Online]. Available: <http://www.galpennergia.com/PT/agalpennergia/os-nossos-negocios/Refinacao-Distribuicao/ARL/Refinacao/Paginas/Didatico-Refinacao.aspx>. [Accessed: 08-Jun-2017].
- [6] “Origens e história - Galp.” [Online]. Available: <http://www.galpennergia.com/PT/agalpennergia/ogruppo/origensehistoria/Paginas/Historia.aspx>. [Accessed: 08-Jun-2017].
- [7] ZILS Global Parques, “Refinaria de Sines,” 2015.
- [8] “Ecoeficiência operacional Estudo de Caso – Refinarias,” 2016.
- [9] “Fabricação III - Galp.” [Online]. Available: <http://www.galpennergia.com/PT/agalpennergia/os-nossos-negocios/Refinacao-Distribuicao/ARL/Refinacao/RefinariaSines/Paginas/FabricacaoIII.aspx>. [Accessed: 11-Jun-2017].
- [10] I. Soares, “Eficiência energética e a ISO 50001,” p. 25, 2000.
- [11] S. Dehran, “Modern Day Automation for Heat Exchanger Monitoring,” *Int. J. Mech. Eng. Appl.*, vol. 5, no. 1, p. 15, 2017.
- [12] N. D. Kundnane, “A Critical Review on Heat Exchangers used in Oil Refinery,” no. March 2015, pp. 1–5, 2015.
- [13] a. C. Bell, K. J. and Mueller, “Fouling in Heat Exchangers,” *Wolver. Eng. Datab. II*, pp. 46–57, 2001.
- [14] H. C. Pusey, “Turbomachinery Condition Monitoring and Failure Prognosis,” *Sound Vib.*, no. 3, pp. 2–12, 2007.
- [15] M. Bohnet, “Fouling of heat transfer surfaces,” *Chem. Eng. Technol.*, vol. 10, no. 1, pp. 113–125, 1987.
- [16] H. Al-Haj Ibrahim, “Fouling in Heat Exchangers,” *Chem. Ind.*, vol. 5, no. 4, pp. 171–175, 1996.
- [17] S. Ahmad, “Heat exchanger performance monitoring,” *Comput. Des.*, vol. 8, no. 3, p. 206, 1976.
- [18] U. Schmitz, T. Friebel, and R. Haber, “Lifetime Estimation of Heat Exchangers with Consideration of On-line Cleaning,” *18^a International Conf. Process Control*, pp. 434–439, 2011.

- [19] J. P. Holman, *Heat transfer*. 2009.
- [20] R. K. Shah and D. P. Sekulic, *Fundamentals of heat exchanger design*. 2003.
- [21] Z. K. Morvay and D. D. Gvozdenac, "Applied Industrial Energy and Environmental Management," no. 2, pp. 1–11.
- [22] M. A. S. Jerónimo, L. F. Melo, A. Sousa Braga, P. J. B. F. Ferreira, and C. Martins, "Monitoring the thermal efficiency of fouled heat exchangers: A simplified method," *Exp. Therm. Fluid Sci.*, vol. 14, no. 4, pp. 455–463, 1997.
- [23] P. Fernand Milcent, "Tópicos dos conhecimentos básicos no estudo de trocadores de calor," 2007.
- [24] A. V. Prasad *et al.*, "Predictive Heat Exchanger Efficiency Monitoring," *Water*, no. January, pp. 1–11, 2005.
- [25] A. C. Rencher and G. B. Schaalje, *Linear Models in Statistics*. 2007.
- [26] H. Durrant-Whyte, "Introduction to estimation and the Kalman filter," *Aust. Cent. F. Robot.*, 2001.
- [27] J. L. Guiñón, E. Ortega, J. García-Antón, and V. Pérez-herranz, "Moving Average and Savitzki-Golay Smoothing Filters Using Mathcad," *Int. Conf. Eng. Educ.*, no. 1, pp. 1–4, 2007.
- [28] E. P. Xing and S. Palaskar, "1 : Factor Analysis and State Space Models," 2017.
- [29] verbindungslosen Datennetzen, L. Burgstahler, D.-I. J. mult Paul Kühn Mitberichter, D.-I. Ralf Lehnert, and T. Dresden, "Bewertung von Mess-und Abschätzverfahren zur Unterstützung dienstgüteorientierter Verkehrslenkung in," 2007.
- [30] H. A. M M Vincent and dr J. ir Kok Ir MJG van de Molengraft juni, "Eindhoven University of Technology MASTER Derivation and identification of the model of a mechanical manipulator Derivation and identification of the model of a mechanical manipulator."
- [31] "A Closer Look At The Advanced CODAS Moving Average Algorithm." [Online]. Available: <https://www.dataq.com/data-acquisition/analysis-software/closer-look-advanced-codas-moving-average-algorithm.html>. [Accessed: 26-Aug-2017].
- [32] S. V. Butler and J. M. Rosenblatt, "Moving averages," *Colloq. Math.*, vol. 113, no. 2, pp. 251–266, 2008.
- [33] E. M. D. G. . Fernandes, "Estatística," *Encontro da Assoc. Nac. dos Programas Pós-Graduação em Adm.*, vol. 26, p. 115, 1999.
- [34] A. Buja and R. Tibshirani, "Linear smoothers and additive models," no. 106, 1987.
- [35] C. Duarte and A. Pereira, "Probabilidades e Estatística," pp. 1–4, 2010.
- [36] S. Manganeli, "A new theory of forecasting," 2006.
- [37] G. Welch and G. Bishop, "An Introduction to the Kalman Filter," *In Pract.*, vol. 7, no. 1, pp. 1–16, 2006.
- [38] T. Friebe, M. Stockmann, and R. Haber, *Heat exchanger fouling detection and lifetime estimation by regression*, vol. 42, no. 19. IFAC, 2009.
- [39] M. Raeesi, M. S. Mesgari, and P. Mahmoudi, "Traffic Time Series Forecasting By Feedforward Neural Network: a Case Study Based on Traffic Data of Monroe," *ISPRS - Int. Arch.*

Photogramm. Remote Sens. Spat. Inf. Sci., vol. XL-2/W3, no. November, pp. 219–223, 2014.

- [40] P. Horta and C. Mendes, “Aplicação das Redes Neurais Artificiais à Detecção dos Mercados Euronext Mais Rentáveis Aplicação das Redes Neurais Artificiais à Detecção dos Mercados Euronext Mais Rentáveis,” *CEFAGE-UE Work. Pap.*, p. 32, 2007.
- [41] P. Glasserman, “Estimation and Confidence Intervals,” *Statistics (Ber.)*, pp. 1–14, 2000.

Anexo I

Equações obtidas através da estimativa da densidade média e da capacidade calorífica média, para a determinação dessas propriedades em função da temperatura para o lado do tubular, e para o lado do corpo.


Tubos						
Equipamento	Temperaturas °C	F. vapor estimada wt/wt(%)	Densidade média (Kg/m ³)	C_p medio (Kcal/kg.°C)	Equação da reta densidade e c_p respetivamente	R^2
HC-E-21	167,20	0,10	717,33	0,71	$y = -0,5631x + 910,12$	100%
	365,60	0,16	570,61	0,86	$y = 0,0008x + 0,5994$	96%
HC-E-22	229,20	0,11	634,87	0,87	$y = -0,4686x + 819,12$	100%
	343,40	0,12	582,65	0,98	$y = 0,001x + 0,6476$	100%
HC-E-24	276,20	0,37	Dados HC-E-21 e HC-E-22	1,17	Valores HC-E-21 e HC-E-22	
	291,70	0,39		1,17	$y = 0,0004x + 1,0494$	98%
HC-E-25	199,40	0,96	Dados HC-E-21 e HC-E-22	1,29	Valores HC-E-21 e HC-E-22	
	243,30	1,00		1,30	$y = 0,0012x + 0,7245$	86%
HC-E-26	153,20	0,82	138,08	1,27	$y = -1,9086x + 430,36$	100%
	199,40	0,96	49,83	1,29	$y = 0,0003x + 1,2234$	100%
HC-E-46	Valores HC-E-24	Valores HC-E-24	Valores HC-E-24	Valores HC-E-24	Valores HC-E-24	

Corpo						
Equipamento	Temperaturas °C	F. vapor estimada wt/wt(%)	Densidade média (Kg/m ³)	C_p medio (Kcal/kg.°C)	Equação da reta densidade e c_p respetivamente	R^2
HC-E-21	429,00	0,57	278,82	1,06	$y = -0,9981x + 705,29$	100%
	288,60	0,38	418,90	0,95	$y = 0,0007x + 0,7436$	100%
HC-E-22	402	0,47	331,38	0,99	$y = 11,719x + 318,82$	100%
	343,4	0,32	436,92	0,91	$y = 0,0007x + 0,6914$	100%
HC-E-24	238,7	0,003	668,2395	0,56	$y = -0,9878x + 904,67$	100%
	263,9	0,01	643,43	0,59	$y = 0,001x + 0,4824$	100%
HC-E-25	60,3	0,002	693,47	0,54	$y = 0,0009x + 0,4931$	99%
	229,5	0,20	453,93	0,68	$y = -1,3136x + 782,66$	97%
HC-E-31	86,3	0,00	837,80	0,54	sem retas	sem retas
	154,4	0,00				
HC-E-46	Valores HC-E-24	Valores HC-E-24	Valores HC-E-24	Valores HC-E-24	Valores HC-E-24	-


Anexo II

Neste Anexo encontram-se as representações gráficas da evolução histórica dos caudais mássicos, para cada um dos permutadores de calor analisados.


HC-E-21




HC-E-22




HC-E-24




HC-E-25




HC-E-31



HC-E-46



Na figura em baixo representada, pretende-se ilustrar o decaimento da eficiência térmica ao longo do tempo, em função da ocorrência de *Shut down*'s na fábrica, e da consequente recuperação de eficiência térmica. Observa-se uma estagnação por parte desses decaimentos, que ocorrem devido a uma saturação por parte da formação de *fouling*, demonstrando que de facto o permutador de calor HC-E-21 apresenta valores de eficiência muito baixos em relação ao seu valor ótimo de funcionamento.




Anexo III


Ilustração das validações para cada permutador de calor para as previsões de 2 semanas, 4 semanas, 6 semanas, 3 meses e 4 meses.



HC-E-21


E-21 2 semanas




E-21 4 semanas












HC-E-22











E-24 2 semanas




E-24 4 semanas












HC-E-25











E-31 2 semanas




E-31 4 semanas











HC-E-46








Arquitetura da rede neuronal

Esquema da rede neuronal utilizada na previsão da eficiência térmica do permutador de calor HC-E-21.



Valores atribuídos aos pesos e à *bias* na arquitetura da rede neuronal

w11	13,04	w12	11,54	w13	16,32	b1	-7,37	w2	6,53
w21	5,66	w22	10,81	w23	-6,28	b2	-11,56		14,46
w31	-12,94	w32	-14,89	w33	-13,59	b3	-1,37		2,01
w14	13,97	w15	11,54	w16	42,34	b4	-4,57		-14,76
w24	5,58	w25	1,18	w26	5,33	b5	-13,51		10,13
w34	-17,13	w35	-14,23	w36	-15,98	b6	-18,22		1,19
w17	13,31	w18	8,79	w19	11,99	b7	-10,40		-14,76
w27	10,65	w28	0,19	w29	1,52	b8	-8,62		10,13
w37	-13,60	w38	-0,20	w39	-13,73	b9	-13,05		1,19

Anexo IV

```

'Inferência estatísticas sobre a reta utilizada para elaborar o estimador, e a sua previsão.

With Application.Workbooks("Modelo de Previsão Linear HC-E-21").Worksheets("Recolha de dados").Cells(5 + cnt, "J")

For kk = lastrowprev - firstrow - cnt - n2 - 1 To lastrowprev - cnt - 1 - firstrow Step 1

    ' Interpolação dos dados provenientes do filtro de ruído.
    interpol = Sheet2.Cells(lastrowprev, "M") * (.Offset(kk, -8)) + Sheet2.Cells(lastrowprev, "AA")
    .Offset(kk, 23).Value = interpol

    ' cálculo do erro quadrado
    erro2 = (.Offset(kk, 2) - .Offset(kk, 23)) ^ 2
    .Offset(kk, 24).Value = erro2

    'Soma do erro quadrado
    err2Sum = Application.WorksheetFunction.Sum(Sheet2.Range(Sheet2.Cells(lastrowprev - n2, "AH"), Sheet2.Cells(lastrowprev, "AH")))

    'Cálculo da variância
    var = err2Sum / (n2 - 1)
    Cells(7, "G").Value = var

    'Cálculo da média da variável independente X
    xMedia = Application.WorksheetFunction.Average(Sheet2.Range(Sheet2.Cells(lastrowprev - n2, "B"), Sheet2.Cells(lastrowprev, "B")))
    YextraMedia = Application.WorksheetFunction.Average(Sheet2.Range(Sheet2.Cells(lastrowprev - n2, "L"), Sheet2.Cells(lastrowprev, "L")))

    'Cálculo dos erros
    .Offset(kk, 25).Value = (.Offset(kk, -8) - xMedia) ^ 2
    .Offset(kk, 26).Value = (.Offset(kk, 23) - YextraMedia) ^ 2
    .Offset(kk, 27).Value = (.Offset(kk, 2) - YextraMedia) ^ 2

    ' Soma dos erros
    xsum = Application.WorksheetFunction.Sum(Sheet2.Range(Sheet2.Cells(lastrowprev - n2, "AI"), Sheet2.Cells(lastrowprev, "AI")))

```

```

Yest2Sum = Application.WorksheetFunction.Sum(Sheet2.Range(Sheet2.Cells(lastrowprev - n2, "AJ"), Sheet2.Cells(lastrowprev, "AJ")))
Yobs2Sum = Application.WorksheetFunction.Sum(Sheet2.Range(Sheet2.Cells(lastrowprev - n2, "AK"), Sheet2.Cells(lastrowprev, "AK")))

' Cálculo do valor t. Este dá-nos a confiança da interpolação.
ttest = a2 * Sqr(xsum) / Sqr(var)
Sheet1.Cells(9, "G").Value = ttest

'Cálculo do R2 (coeficiente de determinação) e R (coeficiente de determinação)
R2extra = Yest2Sum / Yobs2Sum
Sheet1.Cells(8, "G").Value = R2extra
Rextra = Sqr(R2extra)
Sheet1.Cells(8, "H").Value = Rextra

'Cálculo do valor do estimador não tendencioso do desvio padrão, para o último ponto da previsão
sest = Sqr(var * (1 + (1 / (n2 + 1)) + (((Sheet2.Cells(lastrowprev2, "B") - xMedia) ^ 2) / (xsum))))

'Cálculo do estimador não tendencioso do desvio padrão para o parâmetro de declive
spred = Sqr(Sheet1.Cells(7, "G")) / Sqr(xsum)
Sheet1.Cells(12, "G").Value = a2 - spred
Sheet1.Cells(13, "G").Value = a2 + spred
Next kk

```